



TUGAS AKHIR – SS141501

***MODEL OUTPUT STATISTICS UNTUK PRAKIRAAN
CUACA JANGKA PENDEK MENGGUNAKAN
STATISTICALLY INSPIRED MODIFICATION
OF PARTIAL LEAST SQUARE***

**VIRA OKTAVIA KURNIASARI
NRP 1313 100 007**

**Dosen Pembimbing
Dr. Sutikno, S.Si, M.Si
Dr. Urip Haryoko**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



TUGAS AKHIR – SS141501

***MODEL OUTPUT STATISTICS UNTUK PRAKIRAAN
CUACA JANGKA PENDEK MENGGUNAKAN
STATISTICALLY INSPIRED MODIFICATION
OF PARTIAL LEAST SQUARE***

**VIRA OKTAVIA KURNIASARI
NRP 1313 100 007**

**Dosen Pembimbing
Dr. Sutikno, S.Si, M.Si
Dr. Urip Haryoko**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



FINAL PROJECT – SS141501

***MODEL OUTPUT STATISTICS FOR SHORT-TERM
WEATHER FORECAST USING STATISTICALLY
INSPIRED MODIFICATION OF PARTIAL LEAST
SQUARE***

**VIRA OKTAVIA KURNIASARI
NRP 1313 100 007**

**Supervisor
Dr. Sutikno, S.Si, M.Si
Dr. Urip Haryoko**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**

LEMBAR PENGESAHAN

MODEL OUTPUT STATISTICS UNTUK PRAKIRAAN CUACA JANGKA PENDEK MENGGUNAKAN STATISTICALLY INSPIRED MODIFICATION OF PARTIAL LEAST SQUARE

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

Program Studi Sarjana Departemen Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

Vira Oktavia Kurniasari
NRP. 1313 100 007

Disetujui oleh Pembimbing:

Dr. Sutikno, S.Si, M.Si

NIP. 19710313 199702 1 001

()

Dr. Urip Haryoko

NIP. 19591119 198002 1 001

()

Mengetahui,
Kepala Departemen



NIP. 19710929 199512 1 001

SURABAYA, JULI 2017

**MODEL OUTPUT STATISTICS UNTUK PRAKIRAAN
CUACA JANGKA PENDEK MENGGUNAKAN
STATISTICALLY INSPIRED MODIFICATION
OF PARTIAL LEAST SQUARE**

Nama Mahasiswa : Vira Oktavia Kurniasari
NRP : 1313 100 007
Departemen : Statistika
Dosen Pembimbing 1 : Dr. Sutikno, S.Si, M.Si
Dosen Pembimbing 2 : Dr. Urip Haryoko

Abstrak

Perubahan cuaca yang ekstrim seringkali memberikan dampak buruk bagi kehidupan manusia. Dampak buruk tersebut dikarenakan kurangnya informasi prakiraan cuaca yang cepat dan tepat. BMKG telah melakukan kajian pemodelan cuaca dengan data Numerical Weather Project (NWP). Namun, NWP masih menghasilkan ramalan yang bias. Untuk mengatasinya, dilakukan post processing dengan Model Output Statistics (MOS) menggunakan Statistically Inspired Modification of Partial Least Square (SIMPLS). Sebelumnya, dilakukan reduksi dimensi menggunakan Independent Component Analysis (ICA). Observasi cuaca yang digunakan sebagai variabel respon adalah suhu maksimum (T_{max}), suhu minimum (T_{min}), dan kelembapan (RH), sedangkan parameter NWP digunakan sebagai variabel prediktor. Berdasarkan validasi model dengan kriteria RMSEP, disimpulkan bahwa RMSEP untuk T_{max} di Stasiun Juanda ber kriteria baik, sedangkan di Stasiun Soekarno Hatta dan Ngurah Rai ber kriteria sedang. RMSEP untuk T_{min} ber kriteria baik di Stasiun Juanda dan Soekarno Hatta. Namun, RMSEP T_{min} di Stasiun Ngurah Rai ber kriteria buruk. Nilai RMSEP untuk RH ber kriteria baik di tiga stasiun. Nilai %IM atau koreksi bias NWP untuk prakiraan T_{max} , T_{min} , dan RH berkisar antara 26% - 92%.

Kata Kunci- ICA, Kelembapan, MOS, NWP, SIMPLS, Suhu

(Halaman ini sengaja dikosongkan)

MODEL OUTPUT STATISTICS FOR A SHORT-TERM WEATHER FORECAST USING STATISTICALLY INSPIRED MODIFICATION OF PARTIAL LEAST SQUARE

Name : Vira Oktavia Kurniasari
Student Number : 1313 100 007
Department : Statistics
Supervisor 1 : Dr. Sutikno, S.Si, M.Si
Supervisor 2 : Dr. Urip Haryoko

Abstract

The extreme change of weather often gives negative impacts on human life. These negative impacts are due to the lack of information about the weather forecast in a quick and accurate way. BMKG has attempted a study of short-term weather modelling with data of Numerical Weather Project (NWP). However, NWP still produces a bias prediction. To overcome this, post processing is needed with a Model Output Statistics (MOS) using Statistically Inspired Modification of Partial Least Square (SIMPLS). Previously, there is a dimensional reduction using Independent Component Analysis (ICA). The weather observation that is used as the response variable is the maximum temperature (T_{max}), the minimum temperature (T_{min}), and humidity (RH), while the NWP parameter is used as the predictor variable. Based on the model validation with the criteria of RMSEP, it is concluded that the criterion of RMSEP for T_{max} at Juanda Station are in good, while at Soekarno Hatta and Ngurah Rai Station are in average. The criterion of RMSEP for T_{min} is good at Juanda and Soekarno Hatta Station, but poor at Ngurah Rai Station. RMSEP RH is good at the three stations. The value of %IM or the bias correction of NWP for the forecast of T_{max} , T_{min} , and RH ranged from 26% - 92%.

Keyword- *Humidity, ICA, MOS, NWP, SIMPLS, Temperature*

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kehadiran Allah SWT, atas segala rahmat dan karunia-Nya yang tak pernah henti diberikan, sehingga penulis dapat menyelesaikan Tugas Akhir dengan judul ***“Model Output Statistics untuk Prakiraan Cuaca Jangka Pendek Menggunakan Statistically Inspired Modification of Partial Least Square”*** dengan lancar.

Keberhasilan penyusunan Tugas Akhir ini tidak lepas dari banyaknya bantuan dan dukungan yang diberikan dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Bapak Dr. Sutikno, S.Si, M.Si selaku dosen pembimbing 1 dan Bapak Urip Haryoko selaku dosen pembimbing 2 yang telah sabar dalam memberikan bimbingan, saran, dan dukungan selama penyusunan Tugas Akhir walaupun dengan kesibukan yang sangat padat.
2. Bapak Dr. rer. pol. Heri Kuswanto, S.Si, M.Si dan Dr. Purhadi, M.Sc selaku dosen penguji yang telah memberikan banyak bantuan dan masukan untuk kesempurnaan Tugas Akhir ini.
3. Bapak Agus Rubiawan dan Ibu Soegijarti sebagai orangtua penulis yang selalu memberikan dukungan, kasih sayang, semangat, dan doa yang tidak ada hentinya, yang menjadi semangat bagi penulis dalam menyelesaikan Tugas Akhir.
4. Bapak Dr. Suhartono selaku Kepala Departemen Statistika ITS.
5. Bapak Drs. Haryono, M.SIE selaku dosen wali penulis, seluruh dosen yang telah memberikan ilmu dan pengetahuan yang tak ternilai harganya, serta segenap karyawan Jurusan Statistika ITS.
6. Semua pihak yang telah memberikan bantuan hingga penyusunan laporan Tugas Akhir ini dapat terselesaikan.

Penulis berharap hasil Tugas Akhir ini dapat bermanfaat bagi kita semua. Dengan kerendahan hati penulis menyadari masih banyak terdapat kekurangan dalam buku ini, sehingga

penulis mengharapkan saran dan kritik yang membangun demi kesempurnaan Tugas Akhir ini. Akhir kata, semoga kebaikan dan bantuan yang telah diberikan kepada penulis dibalas dengan kebaikan yang lebih besar lagi oleh Tuhan Yang Maha Esa. Aamiin.

Surabaya, Mei 2017

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
COVER PAGE	iii
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
DAFTAR LAMPIRAN	xxi
BAB I PENDAHULUAN	
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	5
1.5 Batasan Penelitian.....	6
BAB II TINJAUAN PUSTAKA	
2.1 <i>Independent Component Analysis</i>	7
2.1.1 Konsep Dasar ICA.....	8
2.1.2 <i>Preprocessing ICA</i>	10
2.1.3 Algoritma fastICA	11
2.2 <i>Model Output Statistics (MOS)</i>	12
2.3 <i>Partial Least Square (PLS)</i>	13
2.3.1 Regresi <i>Partial Least Square</i>	14
2.3.2 <i>Statistically Inspired Modification Partial Least Square</i>	17
2.4 Validasi Model	20
2.5 Ukuran Pengkoreksi Bias.....	21
2.6 <i>Numerical Weather Prediction (NWP)</i>	22
2.7 Suhu	25
2.8 Kelembapan	27

BAB III METODOLOGI PENELITIAN

3.1	Sumber Data	29
3.2	Variabel Penelitian	29
3.2.1	Variabel Respon	29
3.2.2	Variabel Prediktor	29
3.3	Struktur Data	32
3.4	Langkah Analisis	34
3.5	Diagram Alir	36

BAB IV ANALISIS DAN PEMBAHASAN

4.1	Pemodelan SIMPLS	37
4.1.1	Deskripsi Unsur Cuaca	37
4.1.2	Reduksi Dimensi Data NWP	39
4.1.3	Penentuan Jumlah Komponen Optimal	41
4.1.4	Menghitung Pembobot SIMPLS.....	42
4.1.5	Membentuk <i>X-scores</i>	43
4.1.6	Membentuk Matriks Faktor <i>Loadings</i> untuk X	45
4.1.7	Membentuk Matriks Faktor <i>Loadings</i> Untuk Y	46
4.1.8	Menghitung Koefisien Regresi	46
4.1.9	Menyusun Model SIMPLS.....	47
4.2	Validasi Model	50
4.3	Perbandingan Akurasi Prakiraan MOS dengan NWP	53

BAB V KESIMPULAN DAN SARAN

5.1	Kesimpulan	55
5.2	Saran	56

DAFTAR PUSTAKA	57
-----------------------------	----

LAMPIRAN	61
-----------------------	----

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Ilustrasi PCA (a) dan ICA (b).....	7
Gambar 2.2 Algoritma SIMPLS	19
Gambar 2.3 Ilustrasi Kondisi Nyata (a) dengan Representasi NWP (b)	24
Gambar 2.4 Diagram Alur Proses Sistem WRF-EMS	25
Gambar 3.1 Pengukuran NWP Model WRF-EMS dalam Grid 3 x 3	30
Gambar 3.2 Diagram Alir Penelitian.....	36
Gambar 4.1 Perbandingan Nilai Dugaan T_{\max} pada Data Observasi, SIMPLS dan NWP.....	52
Gambar 4.2 Perbandingan Nilai Dugaan T_{\min} pada Data Observasi, SIMPLS dan NWP.....	52
Gambar 4.3 Perbandingan Nilai Dugaan RH pada Data Observasi, SIMPLS dan NWP.....	53

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

	Halaman
Tabel 2.1 Kriteria Nilai RMSEP Suhu dan Kelembapan....	21
Tabel 2.2 Lama Penyinaran Matahari Maksimal Selama Musim Panas di Beberapa Garis Lintang	26
Tabel 3.1 Lokasi Stasiun Pengamatan	29
Tabel 3.2 Parameter NWP Model WRF-EMS.....	29
Tabel 3.3 Struktur Data Penelitian.....	33
Tabel 4.1 Nilai Rataan dan Standar Deviasi	37
Tabel 4.2 Nilai Eigen dan Varians Kumulatif di Tiga Stasiun.....	39
Tabel 4.3 Jumlah Komponen Variabel NWP di Stasiun Juanda.....	40
Tabel 4.4 Nilai PRESS yang Terbentuk di Stasiun Juanda	41
Tabel 4.5 Jumlah Komponen Optimal dan Nilai PRESS di Tiga Stasiun	42
Tabel 4.6 Nilai Pembobot X	43
Tabel 4.7 Nilai <i>X-scores</i>	44
Tabel 4.8 Matriks Faktor <i>Loadings</i> untuk X.....	45
Tabel 4.9 Matriks Faktor <i>Loadings</i> untuk Y.....	46
Tabel 4.10 Koefisien Regresi SIMPLS.....	46
Tabel 4.11 Model Prediksi dengan SIMPLS	47
Tabel 4.12 Nilai R^2 di Tiga Stasiun	49
Tabel 4.13 Nilai Prediksi di Stasiun Juanda	50
Tabel 4.14 Nilai RMSEP Model SIMPLS.....	50
Tabel 4.15 Nilai Prediksi Model SIMPLS dengan NWP dan Observasi.....	51
Tabel 4.16 Nilai %IM	54

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data NWP Stasiun Juanda Variabel <i>Dew2m</i>	61
Lampiran 2 Data Observasi Stasiun Juanda	62
Lampiran 3 Data NWP Stasiun Soekarno Hatta Variabel <i>Dew2m</i>	63
Lampiran 4 Data Observasi Stasiun Soekarno Hatta	64
Lampiran 5 Data NWP Stasiun Ngurah Rai Variabel <i>Dew2m</i>	65
Lampiran 6 Data Observasi Stasiun Ngurah Rai	66
Lampiran 7 Rata-rata dan Standar Deviasi Variabel NWP Stasiun Juanda	67
Lampiran 8 Rata-rata dan Standar Deviasi Variabel NWP Stasiun Soekarno Hatta	68
Lampiran 9 Rata-rata dan Standar Deviasi Variabel NWP Stasiun Ngurah Rai	69
Lampiran 10 Jumlah Komponen Independen Variabel NWP Pada Stasiun Soekarno Hatta	70
Lampiran 11 Jumlah Komponen Independen Variabel NWP Pada Stasiun Ngurah Rai	71
Lampiran 12 Nilai Press yang Terbentuk Pada Stasiun Soekarno Hatta	72
Lampiran 13 Nilai Press yang Terbentuk Pada Stasiun Ngurah Rai.....	72
Lampiran 14 Nilai Pembobot X untuk Pemodelan SIMPLS di Stasiun Soekarno Hatta.....	73
Lampiran 15 Nilai Pembobot X untuk Pemodelan SIMPLS di Stasiun Ngurah Rai	74
Lampiran 16 Nilai <i>X-scores</i> di Stasiun Soekarno Hatta	75
Lampiran 17 Nilai <i>X-scores</i> di Stasiun Ngurah Rai	76

Lampiran 18	Matriks Faktor <i>Loadings</i> untuk X di Stasiun Soekarno Hatta	77
Lampiran 19	Matriks Faktor <i>Loadings</i> untuk X di Stasiun Ngurah Rai	79
Lampiran 20	Matriks Faktor <i>Loadings</i> untuk Y di Stasiun Soekarno Hatta.....	79
Lampiran 21	Matriks Faktor <i>Loadings</i> untuk Y di Stasiun Ngurah	
Lampiran 22	Rai	79
Lampiran 23	Koefisien Regresi SIMPLS Stasiun Soekarno Hatta.....	76
Lampiran 24	Koefisien Regresi SIMPLS Stasiun Ngurah Rai.....	81
Lampiran 25	Model Prediksi di Stasiun Juanda	82
Lampiran 26	Model Prediksi di Stasiun Soekarno Hatta	83
Lampiran 27	Model Prediksi di Stasiun Ngurah Rai.....	84
Lampiran 28	Nilai Prediksi di Stasiun Soekarno Hatta.....	85
Lampiran 29	Nilai Prediksi di Stasiun Ngurah Rai	86
Lampiran 30	Perbandingan Dugaan Data Observasi, SIMPLS, dan NWP di Stasiun Soekarno Hatta.....	87
Lampiran 31	Perbandingan Dugaan Data Observasi, SIMPLS, dan NWP di Stasiun Ngurah Rai ...	88
Lampiran 32	Syntax Program R.....	90

BAB I

PENDAHULUAN

1.1 Latar Belakang

Cuaca merupakan faktor yang tidak dapat dipisahkan dari dinamisnya kehidupan manusia terkait dalam pemanfaatannya yang cukup luas, antara lain di bidang transportasi (penerbangan dan pelayaran), pertanian, sistem peringatan dini (kekeringan dan banjir), dan lain lain (BMKG, 2014). Namun, perubahan cuaca yang ekstrim dapat menyebabkan dampak buruk seperti bencana banjir yang diakibatkan karena peningkatan curah hujan dan kekeringan yang diakibatkan oleh musim kemarau berkepanjangan (PAKLIM, 2016). Dampak buruk karena cuaca ekstrim tersebut dapat dikarenakan kurangnya informasi prakiraan cuaca yang cepat dan hasil yang belum mendekati keadaan sebenarnya. Informasi mengenai prakiraan cuaca dapat bermanfaat sebagai *early warning* (antisipasi dini) terhadap dampak buruk yang diakibatkan oleh cuaca ekstrim, khususnya dalam bidang transportasi (penerbangan dan pelayaran). Misalnya pada maskapai penerbangan, informasi mengenai kondisi cuaca harus diketahui pilot sebagai syarat menerbangkan pesawat sebelum berangkat ke tempat tujuan. Kondisi inilah yang menyebabkan informasi prakiraan cuaca yang cepat dan tepat menjadi suatu hal yang penting untuk meminimalkan dampak buruk akibat cuaca yang sering disebut hidrometeorologi.

Secara geografis, Indonesia merupakan negara kepulauan yang berada di jalur cincin api (*ring of fire*) Pasifik dan terletak di daerah iklim tropis dengan dua musim yaitu panas dan hujan. Kondisi iklim seperti ini digabungkan dengan kondisi topografi permukaan dan batuan yang relatif beragam dapat menimbulkan dampak buruk, seperti terjadinya bencana hidrometeorologi. Seiring dengan berkembangnya waktu dan meningkatnya aktivitas manusia, kerusakan lingkungan hidup cenderung semakin parah dan memicu meningkatnya intensitas bencana hidrometeorologi di Indonesia. Badan Nasional Penanggulangan Bencana (2016)

menyatakan bahwa 95 persen bencana di Indonesia disebabkan karena hidrometeorologi dan berpotensi meningkat di tahun 2017. Menyikapi fenomena tersebut, maka diperlukan kemampuan dan metode yang efektif dalam melakukan prakiraan cuaca, khususnya prakiraan cuaca jangka pendek untuk periode 1-7 hari kedepan, sehingga diharapkan dapat digunakan sebagai *early warning* terhadap bencana hidrometeorologi.

Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) sebagai lembaga resmi yang memberikan informasi cuaca, telah berupaya melakukan kajian pemodelan cuaca jangka pendek melalui pendekatan obyektif dengan menggunakan data komponen cuaca, yaitu data *Numerical Weather Prediction* (NWP). Namun, NWP menghasilkan ramalan yang bias terutama untuk wilayah dengan topografi berbukit dan tutupan vegetasi yang kompleks. Berdasarkan sudut pandang NWP yang diukur secara global dalam grid tertentu pada lokasi domain yang tinggi akan menghasilkan informasi cuaca yang homogen pada beberapa daerah yang masuk dalam grid pengukuran. Akibatnya, model NWP akan menghasilkan ramalan cuaca yang bias apabila digunakan untuk meramalkan cuaca lokal (Wilks, 2006). Idowu dan Rautenbach (2008) menyatakan bahwa hasil ramalan NWP yang bias juga dapat disebabkan karena keadaan atmosfer yang fluktuatif dan terbatasnya perhitungan matematis untuk memodelkan keadaan fisik dari dinamika atmosfer tersebut. Oleh karena itu, perlu dilakukan pemrosesan secara statistik (*statistical post processing*) untuk mengoptimalkan pemanfaatan luaran NWP. Terdapat dua metode yang dapat digunakan dalam melakukan prakiraan cuaca yang tidak secara langsung dihasilkan oleh model NWP, yaitu *Perfect Prognosis Method* dan *Model Output Statistics* (MOS). *Perfect Prognosis Method* merupakan suatu metode yang diperkenalkan oleh Klein pada tahun 1959 dengan tujuan untuk mencari hubungan antara variabel yang diduga dengan variabel yang dapat diramal oleh model dinamis. Kemudian, hubungan kedua variabel tersebut diterapkan pada luaran model NWP.

Metode kedua yang sering digunakan adalah *Model Output Statistics* (MOS). MOS merupakan teknik peramalan cuaca melalui pendekatan obyektif yang menghubungkan antara variabel respon dan variabel prediktor dari model numerik pada beberapa proyeksi waktu (Glahn dan Lowry, 1972). MOS merupakan suatu model berbasis regresi yang menghubungkan antara variabel respon berupa hasil observasi unsur cuaca dan variabel prediktor berupa luaran NWP. MOS juga bertujuan untuk mengkoreksi bias dari model NWP (Idowu dan Rautenbach, 2008). Metode ini dapat diterapkan dengan memanfaatkan data observasi, sarana, dan prasarana yang dimiliki BMKG tanpa harus mengadakan peralatan baru. BMKG telah mengkaji menggunakan model MOS sejak tahun 2004. Namun, berdasarkan hasil verifikasi Bidang Analisa Meteorologi BMKG tahun 2011 menunjukkan bahwa prakiraan yang dihasilkan masih belum memuaskan karena masih terdapat bias yang cukup tinggi (Setiarnoputera, 2015). Permasalahan dalam pemodelan MOS terletak pada penyusunan model hubungan antara variabel respon (hasil observasi cuaca permukaan) dan variabel prediktor (hasil ramalan NWP), serta pereduksian domain NWP (Safitri, 2012).

Data NWP diambil dalam 9 grid pengukuran di setiap lokasi untuk masing-masing variabel, sehingga penyusunan MOS melibatkan banyak variabel prediktor dan variabel respon. Banyaknya variabel tersebut mengakibatkan terjadi kasus multikolinearitas. Multikolinearitas pada setiap variabel di 9 grid pengukuran tersebut dapat diatasi dengan melakukan reduksi dimensi. Metode reduksi dilakukan dengan tetap mempertahankan struktur informasi pada data asli ke dalam data tereduksi (Idayati, 2014). Salah satu metode reduksi dimensi yang digunakan adalah *Independent Component Analysis* (ICA). Anuravega (2013) menyatakan bahwa sebagian besar MOS dengan reduksi dimensi menggunakan ICA menghasilkan nilai RMSE yang lebih kecil daripada RMSE NWP. Multikolinearitas juga dapat diatasi dengan *Partial Least Square* (PLS). PLS merupakan metode statistika yang efisien untuk memprediksi data dengan banyak variabel yang

mungkin saling berkorelasi. Metode PLS dibedakan menjadi dua, yaitu *univariate response* PLS yang dikenal dengan PLS1 dan *multivariate response* PLS yang terbagi menjadi dua yaitu PLS2 dan SIMPLS (Boulesteix, Laure, dan Strimmer, 2006). Pada penelitian kali ini digunakan *Statistically Inspired Modification of Partial Least Square* (SIMPLS) yang merupakan modifikasi dari PLS2. Metode tersebut merupakan metode dengan pendekatan nonparametrik yang tidak terlalu ketat dengan asumsi (*soft modelling*), sehingga diperkirakan akan meningkatkan akurasi hasil ramalan.

Pemodelan MOS berbasis regresi pernah diterapkan oleh Li (2006) dengan pendekatan *Statistically Inspired Modification of Partial Least Square* (SIMPLS). Li (2006) menyimpulkan bahwa SIMPLS berpotensi untuk diterapkan pada *lunar hyperspectral imagery* (M3 Mission) untuk melakukan prediksi komposisi dilihat dari nilai RMSE yang kecil. Safitri (2012) melakukan penelitian dengan pendekatan *Projection Pursuit Regression* (PPR) yang menyimpulkan bahwa nilai RMSEP model MOS PPR secara konsisten lebih kecil daripada model NWP untuk semua unsur cuaca di empat stasiun pengamatan dan dapat memperbaiki model NWP mencapai 86%. Penelitian serupa juga dilakukan oleh Septiana (2014) dengan pendekatan SIMPLS. Hasil penelitian tersebut menyimpulkan bahwa nilai RMSEP memiliki kriteria baik di beberapa stasiun pengamatan dan dapat mengkoreksi bias NWP antara 20,20% sampai 89,75%. Setiarnoputera (2015) melakukan penelitian dengan menggunakan metode PLS2 dan menghasilkan kesimpulan bahwa PLS2 dapat memperbaiki bias prakiraan NWP berkisar antara 13,99% - 89,75% di tiap stasiun pengamatan.

Berdasarkan uraian tersebut, penelitian ini dilakukan untuk mendapatkan model MOS dengan metode SIMPLS melalui prapemrosesan ICA. Selanjutnya, hasil pemodelan dibandingkan dengan hasil model NWP dengan kriteria RMSEP untuk mengetahui akurasi metode SIMPLS dalam melakukan prakiraan cuaca dan kriteria %IM (*Percentage Improval*) untuk mengetahui koreksi bias model MOS dan model NWP.

1.2 Rumusan Masalah

Suhu dan kelembapan merupakan unsur-unsur yang berpengaruh terhadap kondisi cuaca. BMKG telah melakukan prakiraan cuaca terkait suhu dan kelembapan dalam jangka pendek untuk diinformasikan kepada masyarakat. Namun, informasi prakiraan cuaca yang diolah BMKG menggunakan luaran NWP masih menghasilkan ramalan dengan bias yang cukup besar. Hal tersebut dikarenakan NWP memberikan informasi cuaca yang bersifat homogen karena diukur pada skala global, sehingga apabila informasi prakiraan cuaca dari model NWP digunakan untuk meramal cuaca lokal, maka akan menghasilkan ramalan yang tidak konsisten akibat bias yang ditimbulkan. Metode yang dapat digunakan untuk mengoptimalkan luaran NWP adalah *Model Output Statistics* (MOS) dengan salah satu pendekatan *Multivariate Partial Least Square*, yaitu *Statistically Inspired Modification of Partial Least Square* (SIMPLS).

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Mendapatkan model MOS dengan metode SIMPLS untuk meramalkan suhu dan kelembapan.
2. Mengetahui akurasi hasil ramalan model MOS dengan metode SIMPLS.
3. Mengetahui kebaikan metode SIMPLS dalam mengkoreksi bias model NWP.

1.4 Manfaat Penelitian

Adapun manfaat yang ingin diperoleh dari penelitian ini adalah sebagai berikut.

1. Bagi peneliti, dapat memberikan tambahan wawasan terkait penerapan ilmu statistika tentang *Model Output Statistics* (MOS) khususnya di bidang meteorologi.
2. Bagi BMKG, hasil penelitian ini dapat dijadikan bahan acuan untuk mengoptimalkan luaran NWP dengan *Model Output Statistics* (MOS) dalam memodelkan prakiraan

cuaca jangka pendek untuk komponen suhu dan kelembapan.

3. Bagi masyarakat, dapat memberikan informasi prakiraan cuaca yang lebih akurat sebagai bentuk antisipasi dini terhadap perubahan cuaca.

1.5 Batasan Penelitian

Penelitian ini dilakukan di tiga lokasi stasiun dengan menggunakan data NWP hasil model aplikasi *Weather Research and Forecasting Environmental Modelling System* (WRF-EMS).


BAB II

TINJAUAN PUSTAKA

2.1 *Independent Component Analysis*

Independent Component Analysis (ICA) adalah suatu teknik perhitungan statistik untuk menemukan faktor-faktor tersembunyi yang mendasari sekumpulan variabel random, pengukuran, atau sinyal-sinyal (Hyvärinen dan Oja, 2000). Permasalahan utama data multivariat adalah menemukan representasi yang tepat. Seringkali representasi diperoleh dari transformasi linier menggunakan data asli. ICA merupakan salah satu metode transformasi linier, selain PCA, analisis faktor, dan *projection pursuit*. ICA menjadi solusi yang tepat digunakan pada data yang tidak memenuhi asumsi normal multivariat. Salah satu aplikasi metode ICA yaitu digunakan untuk memisahkan sinyal-sinyal tercampur yang berasal dari sumber yang saling bebas.

Hyvärinen (2002) memisalkan konsep ICA seperti *cocktail-party effect*, yaitu dua orang yang berdiri di sebuah ruangan dan berbicara secara bersamaan. Jika terdapat dua *microphone* yang ditempatkan di dua tempat berbeda dalam suatu ruangan, *microphone* tersebut akan merekam kombinasi linier dari dua suara. Gambar 2.1 menunjukkan perbedaan ICA dan PCA secara visual.



Gambar 2.1 Ilustrasi PCA (a) dan ICA (b)
(Langlois, Chartier, dan Gosselin, 2010)

Gambar tersebut menunjukkan hasil komponen menjadi dua kombinasi suara baru. Metode PCA berhasil memisahkan suara dua orang seperti yang ditunjukkan oleh Gambar 2.1 (a). Bila *non-Gaussianity* terpenuhi, metode ICA akan memberikan hasil yang berbeda dimana ICA mampu membedakan suara setiap orang dari kombinasi linier suara mereka dengan hasil yang konstan (tinggi dan kerapatan yang sama). Hal tersebut dapat dilihat pada Gambar 2.1 (b).

ICA melakukan beberapa asumsi terhadap data yang akan diolah agar invers matrik \mathbf{W} dapat ditentukan. Asumsi-asumsi tersebut menurut Wijayanto, Hidayat, dan Suyanto (2011) adalah sebagai berikut.

a. Data bersifat *Non-Gaussian*

Source matrix harus bersifat *non-gaussian* (tidak mengikuti distribusi normal) dikarenakan \mathbf{W} merupakan suatu matriks yang memaksimumkan *nongaussianity*.

b. Data *Statistically Independent*

Asumsi *statistically independent* adalah data tidak berhubungan satu sama lainnya (*un-correlated*). Artinya, *source matrix* satu dengan yang lain harus tidak berhubungan.

c. *Square Mixing Matrix*

Selain dua syarat yang telah disebutkan di atas, terdapat syarat lain yang juga cukup penting dalam metode ICA, yaitu matrix pencampur merupakan matriks *square*. Matriks *square* yaitu matriks yang memiliki jumlah baris dan jumlah kolom yang sama.

2.1.1 Konsep Dasar ICA

Penetapan ICA dapat menggunakan model statistika “variabel laten”. Misal sebanyak m dimensi x_1, x_2, \dots, x_m dari m komponen independen, maka persamaan umumnya sebagai berikut.

$$x_j = a_{j1}s_1 + a_{j2}s_2 + \dots + a_{jm}s_m ; j = 1, 2, \dots, m \quad (2.1)$$

Dalam notasi matriks, vektor random pengamatan $\mathbf{x} = [x_1, x_2, \dots, x_m]^T$ yang m elemen-elemennya merupakan gabungan dari elemen independen m dari vektor random $\mathbf{s} = [s_1, s_2, \dots, s_m]^T$. Maka diberikan notasi matriks berikut.

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (2.2)$$

dimana,

\mathbf{x} = Vektor kombinasi linier dari komponen independen *non-Gaussian*

\mathbf{s} = Vektor komponen independen

\mathbf{A} = Matriks linier gabungan (*mixing matrix*) $m \times m$

Model ICA adalah model generatif yang menggambarkan bagaimana data pengamatan dihasilkan dengan proses penggabungan (*mixing*) komponen s_i . Komponen-komponen independen adalah variabel laten, artinya komponen tersebut tidak dapat diamati secara langsung. Matriks \mathbf{A} diasumsikan tidak diketahui. Semua yang diamati adalah vektor random \mathbf{x} , dan peneliti harus mengestimasi \mathbf{A} dan \mathbf{s} . Tujuan ICA adalah menemukan matriks *unmixing* \mathbf{W} (invers dari \mathbf{A}) yang akan diberikan oleh \mathbf{Y} dengan pendekatan terbaik \mathbf{S} sebagai berikut.

$$\mathbf{Y} = \mathbf{W}\mathbf{x} \approx \mathbf{S} \quad (2.3)$$

Menurut Haykin (2009), terdapat dua algoritma utama dalam ICA yaitu algoritma berdasarkan *minimization of mutual information* (InfoMax) dan *maximixation of non-Gaussianity* (fastICA). Algoritma InfoMax merupakan algoritma model ICA berdasarkan fungsi *non-linear*, sedangkan algoritma FastICA adalah algoritma model ICA dengan memaksimalkan nilai *non-gaussian* suatu variabel acak. Masing-masing algoritma memiliki kelebihan satu sama lain dan terus mengalami penyempurnaan dari tahun ke tahun. Pada Tugas Akhir ini digunakan algoritma FastICA dimana algoritma tersebut merupakan algoritma yang paling sederhana dan cepat konvergen dibandingkan algoritma ICA yang lainnya.

2.1.2 *Preprocessing ICA*

Berikut merupakan beberapa teknik *preprocessing* sebelum mengaplikasikan algoritma ICA agar lebih mudah diestimasi.

a. *Centering*

Teknik *preprocessing* ini digunakan untuk menyederhanakan algoritma ICA karena *mean* dapat diestimasi. Hal yang paling mendasari adalah pemusatan \mathbf{x} . Prinsipnya adalah dengan mengurangi data tersebut dengan rata-rata data ($E\{\mathbf{x}\}$), sehingga \mathbf{x} menjadi variabel yang memiliki rerata nol (*zero mean*). Untuk menjalankan proses *centering*, dapat digunakan rumus sebagai berikut.

$$\mathbf{x}^* = \mathbf{x} - E[\mathbf{x}] \quad (2.4)$$

b. *Whitening*

Sebelum menerapkan algoritma ICA (setelah *centering*), hal yang perlu dilakukan adalah mentransformasi vektor \mathbf{x} secara linier, sehingga diperoleh vektor baru $\tilde{\mathbf{x}}$ yang telah melalui proses *whitening*, yaitu komponennya tidak berkorelasi dan variansnya memiliki satuan yang sama. Dengan kata lain, matriks kovarian dari $\tilde{\mathbf{x}}$ sama dengan matriks identitas.

$$E\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\} = \mathbf{I} \quad (2.5)$$

Salah satu metode yang populer adalah dengan menggunakan nilai eigen dekomposisi dari matriks kovarian yang ditunjukkan oleh persamaan (2.6).

$$E\{\mathbf{x}\mathbf{x}^T\} = \mathbf{E}\mathbf{D}\mathbf{E}^T \quad (2.6)$$

dimana,

\mathbf{E} = matriks orthogonal dari eigenvektor $E\{\mathbf{x}\mathbf{x}^T\}$

\mathbf{D} = matriks diagonal dari nilai eigennya

Teknik *whitening* dapat diperoleh dengan rumus sebagai berikut.

$$\tilde{\mathbf{x}} = \mathbf{E}\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T\mathbf{X} \quad (2.7)$$

Dengan persamaan tersebut dapat memudahkan untuk melakukan pembuktian bahwa diperoleh ekspektasi pada persamaan (2.5). *Whitening* mentransformasi matriks *mixing* \mathbf{A} menjadi $\tilde{\mathbf{A}}$. Dari persamaan (2.2) dan (2.7) diperoleh bahwa,

$$\tilde{\mathbf{x}} = \mathbf{E} \mathbf{D}^{-\frac{1}{2}} \mathbf{E}^T \mathbf{A} \mathbf{S} = \tilde{\mathbf{A}} \mathbf{S} \quad (2.8)$$

Dari persamaan tersebut dapat diketahui bahwa matriks *mixing* baru $\tilde{\mathbf{A}}$ adalah orthogonal. Hal tersebut dapat dilihat pada persamaan (2.9) berikut.

$$\mathbf{E}\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\} = \tilde{\mathbf{A}} \mathbf{E}\{\mathbf{S}\mathbf{S}^T\} \tilde{\mathbf{A}}^T = \mathbf{I} \quad (2.9)$$

Proses *whitening* disini bertujuan untuk mengurangi jumlah parameter yang diestimasi karena hanya mengestimasi matriks *mixing* orthogonal yang baru, yaitu matriks $\tilde{\mathbf{A}}$.

2.1.3 Algoritma FastICA

ICA merupakan aturan menemukan arah, yaitu vektor satuan \mathbf{w} sedemikian rupa sehingga proyeksi $\mathbf{w}^T \mathbf{x}$ memaksimalkan *non-gaussianity*. Ketidaknormalan diukur dengan pendekatan negentropi $J(\mathbf{w}^T \mathbf{x})$ yang ditunjukkan oleh persamaan berikut.

$$J(\mathbf{w}^T \mathbf{x}) \propto [E\{G(\mathbf{w}^T \mathbf{x})\} - E\{g(\mathbf{w}^T \mathbf{x})\}] \quad (2.10)$$

FastICA didasarkan pada skema iterasi *fixed-point* untuk menemukan ketidaknormalan maksimum dari $\mathbf{w}^T \mathbf{x}$ yang diukur dengan persamaan (2.15). Dilambangkan dengan derivatif g dari fungsi G nonkuadratik yang digunakan dalam persamaan (2.15), dengan fungsi G diberikan oleh,

$$G_1(u) = \frac{1}{a_1} \log \cosh(a_1 u) \quad (2.11)$$

$$G_2(u) = -\exp\left(-\frac{u^2}{2}\right) \quad (2.12)$$

Dengan nilai derivatif g sebagai berikut,

$$G_1(u) = \frac{1}{a_1} \log \cosh(a_1 u)$$

$$\frac{\partial(G_1)}{\partial u} = \frac{1}{a_1} \frac{1}{\cosh(a_1 u)} \sinh(a_1 u) a_1 \quad (2.13)$$

$$g_1(u) = \frac{\sinh(a_1 u)}{\cosh(a_1 u)}$$

$$g_1(u) = \tanh(a_1 u)$$

$$g_2(u) = u \exp\left(-\frac{u^2}{2}\right) \quad (2.14)$$

dimana $1 \leq a_1 \leq 2$ adalah konstanta yang tepat, seringkali digunakan nilai $a_1=1$.

Bentuk dasar dari algoritma ICA adalah sebagai berikut.

1. Memilih inisial vektor \mathbf{w} (dengan cara acak)
2. Membentuk \mathbf{w}^+ (w baru)

$$\mathbf{w}^+ = E\{\mathbf{x}G(\mathbf{w}^T \mathbf{x})\} - E\{g(\mathbf{w}^T \mathbf{x})\}\mathbf{w} \quad (2.15)$$

3. Menormalisasi nilai \mathbf{w}^+

$$\mathbf{w} = \frac{\mathbf{w}^+}{\|\mathbf{w}^+\|} \quad (2.16)$$

4. Memeriksa konvergensi nilai \mathbf{w} setelah dinormalisasi dengan sebelum normalisasi. Jika tidak konvergen, kembali ke langkah 2.

2.2 Model Output Statistics (MOS)

Model Output Statistics (MOS) pertama kali dikembangkan oleh Glahn dan Lowry pada tahun 1969 dan mulai dipublikasikan antara tahun 1972 hingga 1979. MOS merupakan model yang menghubungkan antara variabel respon dan variabel prediktor dari model numerik dalam beberapa proyeksi waktu dengan model berbasis regresi (Glahn dan Lowry, 1972). Sebagai variabel respon

adalah hasil observasi cuaca pada stasiun pengamatan yang merupakan unsur-unsur cuaca seperti suhu, kelembapan, kecepatan angin, curah hujan, dan sebagainya. Sedangkan, variabel prediktornya adalah parameter dari luaran NWP yang diukur pada berbagai grid dan level. Sampai saat ini MOS telah mengalami perkembangan yang pesat dalam rangka meningkatkan kemampuan prakiraan cuaca jangka pendek.

Secara umum, persamaan matematis MOS diformulasikan seperti persamaan 2.17.

$$\hat{y}_t = \hat{f}_{\text{MOS}}(x_t) \quad (2.17)$$

dimana,

\hat{y}_t = ramalan cuaca saat t

x_t = variabel luaran NWP saat t

Menurut Neilly dan Hanson (2004), MOS mempunyai dua fungsi utama. Pertama, MOS menghasilkan ramalan cuaca kuantitatif ke depan yang mungkin tidak secara eksplisit diperoleh dari model. Kedua, MOS mereduksi *error* dari ramalan NWP dengan memperkecil bias dan pengkoreksian model secara statistik. MOS akan menghasilkan ramalan yang optimal jika terpenuhi syarat-syarat sebagai berikut:

- Periode data *training* yang digunakan dalam pembentukan model seharusnya sepanjang mungkin.
- Model yang terbentuk seharusnya tidak berubah pada kondisi ekstrim selama verifikasi model.
- MOS seharusnya dapat diaplikasikan dan tidak berubah modelnya ketika memasuki tahap validasi model.

2.3 *Partial Least Square (PLS)*

Partial Least Square (PLS) pertama kali diperkenalkan oleh Herman O.A Wold pada tahun 1960 untuk pembangunan model dan metode dengan pendekatan yang berorientasi pada prediksi. Menurut Ramzan dan Khan (2010) dalam Soebagijo (2011), PLS merupakan suatu teknik prediktif yang dapat menangani banyak variabel independen, sekalipun terjadi multikolinearitas diantara variabel-variabel tersebut. PLS bersifat *robust*, artinya parameter

model tidak banyak berubah ketika sampel baru diambil dari total populasi (Geladi dan Kowalski, 1986). Pada metode metode PLS perhitungan komponen utama pada variabel-variabel prediktor (X) dan respon (Y) dilakukan secara bersama-sama melalui proses iterasi. Pada setiap iterasinya varian X dan Y saling mempengaruhi, dimana struktur varian X mempengaruhi kombinasi linier Y dan struktur varian Y mempengaruhi kombinasi linier X (Wigena dan Alamudi, 1997).

Boulesteix (2006) menyatakan bahwa PLS memiliki banyak keunggulan dibandingkan dengan metode lain yaitu: (1) PLS dapat secara langsung memilih variabel yang digunakan, (2) PLS merupakan metode statistik yang sangat efisien untuk memprediksi data sampel kecil dengan banyak variabel yang mungkin berkorelasi, (3) Komputasi yang cepat, sehingga mudah diaplikasikan untuk data yang besar dan tidak memerlukan asumsi-asumsi.

2.3.1 Regresi *Partial Least Square*

Metode PLS diawali dengan standardisasi data variabel X dan variabel Y. Tujuan dari standardisasi data adalah untuk menghasilkan pembobot yang memiliki satuan yang relatif sama antar variabel. Jika sebanyak q variabel respon (Y_1, \dots, Y_q) diprediksi dengan p variabel prediktor (X_1, \dots, X_p), dimana sampel data terdiri atas n pengamatan, maka pasangan datanya dapat ditulis sebagai berikut: (x_t', y_t') , dengan $t=1, \dots, n$. Metode perhitungan standardisasi data ditunjukkan pada persamaan (2.18) sebagai berikut.

$$\begin{aligned} x_{tu}^* &= \frac{x_{tu} - \bar{x}_u}{s_u} \\ y_{tr}^* &= \frac{y_{tr} - \bar{y}_r}{s_r} \end{aligned} \tag{2.18}$$

dengan,

$$\begin{aligned}\bar{x}_u &= \frac{1}{n} \sum_{t=1}^n x_{tu}; s_u = \sqrt{\frac{\sum_{t=1}^n (x_{tu} - \bar{x}_u)^2}{n-1}} \\ \bar{y}_r &= \frac{1}{n} \sum_{t=1}^n y_{tr}; s_r = \sqrt{\frac{\sum_{t=1}^n (y_{tr} - \bar{y}_r)^2}{n-1}}\end{aligned}\quad (2.19)$$

dimana,

x_{tu}^* = data ke- t yang telah distandardisasi untuk variabel ke- u , $u = 1, 2, \dots, p$

y_{tr}^* = data ke- t yang telah distandardisasi untuk variabel ke- r , $r = 1, 2, \dots, q$.

Kemudian, $\mathbf{x}_t = (x_{t1}, \dots, x_{tp})^T$ dihipunkan dalam matrik \mathbf{X} yang berukuran $n \times p$ dan $\mathbf{y}_t = (y_{t1}, \dots, y_{tq})^T$ dihipunkan dalam matrik \mathbf{Y} berukuran $n \times q$, dimana n adalah banyak observasi, p adalah banyaknya parameter prediktor, dan q adalah banyaknya parameter respon. Himpunan matrik \mathbf{X} dan \mathbf{Y} ditunjukkan sebagai berikut.

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}'_1 \\ \vdots \\ \mathbf{x}'_n \end{bmatrix}; \mathbf{Y} = \begin{bmatrix} \mathbf{y}'_1 \\ \vdots \\ \mathbf{y}'_n \end{bmatrix}$$

Ketika $n < p$, metode regresi yang umum digunakan seperti metode kuadrat terkecil (*Ordinary Least Square*) tidak dapat digunakan karena matrik kovarian $(\mathbf{X}'\mathbf{X})$ adalah singular, sedangkan kasus $n < p$ dapat diatasi dengan PLS. Dalam PLS, reduksi dimensi dan regresinya dilakukan secara simultan. Regresi PLS didasarkan pada dekomposisi komponen laten yang ditunjukkan pada persamaan (2.18)

$$\begin{aligned}\mathbf{X} &= \mathbf{TP}' + \mathbf{E} \\ \mathbf{Y} &= \mathbf{TQ}' + \mathbf{F}\end{aligned}\quad (2.20)$$

dimana,

T = matrik komponen laten (*score matrices*) untuk n pengamatan yang berukuran $n \times c$

P = matrik koefisien (*loadings matrices*) variabel Y yang berukuran $p \times c$

Q = matrik koefisien (*loadings matrices*) variabel X yang berukuran $q \times c$

E dan **F** = matrik residual

PLS membentuk matrik komponen laten **T** sebagai transformasi linier dari **X** seperti persamaan berikut.

$$\mathbf{T} = \mathbf{XW} \quad (2.21)$$

selanjutnya **W** dan **T** dinotasikan sebagai berikut.

$$\mathbf{w}_h = \begin{bmatrix} w_{1h} \\ \vdots \\ w_{ph} \end{bmatrix}; \mathbf{t}_h = \begin{bmatrix} t_{1h} \\ \vdots \\ t_{nh} \end{bmatrix}$$

dengan c adalah banyaknya komponen laten untuk $h = 1, 2, \dots, c$. Komponen laten digunakan untuk melakukan prediksi terhadap **Y** menggantikan variabel asalnya yaitu **X**. Ketika **T** sudah terbentuk, maka diperoleh **Q'** melalui metode kuadrat terkecil sebagai berikut.

$$\hat{\mathbf{Q}}' = (\mathbf{T}'\mathbf{T})^{-1}\mathbf{T}'\mathbf{Y} \quad (2.22)$$

Dengan demikian matrik **B** yang merupakan matrik koefisien regresi untuk model $\mathbf{Y} = \mathbf{XB} + \mathbf{E}$ diperoleh dari penurunan berikut.

$$\mathbf{Y} = \mathbf{TQ}' + \mathbf{E}$$

$$\mathbf{XB} = \mathbf{TQ}' \quad (2.23)$$

$$\mathbf{XB} = \mathbf{XWQ}'$$

$$\mathbf{B} = \mathbf{WQ}'$$

Dengan memasukkan (2.22) ke persamaan (2.23) maka diperoleh dugaan **B** sebagai berikut.

$$\hat{\mathbf{B}} = \mathbf{W}(\mathbf{T}'\mathbf{T})^{-1}\mathbf{T}'\mathbf{Y} \quad (2.24)$$

Maka dugaan \mathbf{Y} diperoleh berdasarkan persamaan (2.25)

$$\hat{\mathbf{Y}} = \mathbf{X}\hat{\mathbf{B}}$$

$$\hat{\mathbf{Y}} = [\mathbf{T}\mathbf{W}^{-1}\mathbf{W}(\mathbf{T}'\mathbf{T})^{-1}\mathbf{T}'\mathbf{Y}] \quad (2.25)$$

$$\hat{\mathbf{Y}} = [\mathbf{T}(\mathbf{T}'\mathbf{T})^{-1}\mathbf{T}'\mathbf{Y}]$$

$$\hat{\mathbf{Y}} = [\mathbf{T}(\mathbf{T}^T\mathbf{T})^{-1}\mathbf{T}^T\mathbf{Y}]$$

2.3.2 *Statistically Inspired Modification Partial Least Square*

Statistically Inspired Modification Partial Least Square (SIMPLS) termasuk dalam PLS *multivariate response* yang diperkenalkan pertama kali oleh Sijmen de Jong pada tahun 1993. SIMPLS merupakan modifikasi dari PLS2 (bentuk lain dari PLS1) yang juga termasuk dalam PLS *multivariate response*. Perbedaan antara SIMPLS dengan PLS2 adalah algoritma untuk menghitung matrik \mathbf{W} .

Algoritma SIMPLS

Berikut ini merupakan algoritma SIMPLS untuk mendapatkan matrik bobot \mathbf{W} .

$$\mathbf{S}_0 = \mathbf{X}'\mathbf{Y} \quad (2.26)$$

$$\mathbf{M}_0 = \mathbf{X}'\mathbf{X} \quad (2.27)$$

$$\mathbf{C}_0 = \mathbf{I} \quad (2.28)$$

Untuk $h = 1, 2, \dots, c$; dimana c merupakan jumlah komponen laten.

1. Menghitung pembobot (\mathbf{w}_h^*)

$$\mathbf{r}_h = \mathbf{S}_{h-1}'\mathbf{S}_{h-1} \quad (2.29)$$

$$\mathbf{w}_h^* = \mathbf{S}_{h-1}'\mathbf{r}_h \quad (2.30)$$

2. Menormalisasi pembobot (\mathbf{w}_h)

$$\mathbf{w}_h = \frac{\mathbf{w}_h^*}{\sqrt{\mathbf{c}_h}} \quad (2.31)$$

$$\mathbf{c}_h = \mathbf{w}_h^{*'} \mathbf{M}_{h-1} \mathbf{w}_h^* \quad (2.32)$$

3. Menghitung komponen laten (\mathbf{t}_h)

$$\mathbf{t}_h = \mathbf{X} \mathbf{w}_h \quad (2.33)$$

4. Menghitung matriks loading

$$\mathbf{p}_h = \mathbf{M}_{h-1} \mathbf{w}_h \quad (2.34)$$

$$\mathbf{q}_h = \mathbf{S}_{h-1}' \mathbf{w}_h \quad (2.35)$$


5. Memperbarui inisiasi iterasi

$$\mathbf{C}_h = \mathbf{C}_{h-1} - (\mathbf{c}_h \mathbf{p}_h)(\mathbf{c}_h \mathbf{p}_h)' \quad (2.36)$$

$$\mathbf{M}_h = \mathbf{M}_{h-1} - \mathbf{p}_h \mathbf{p}_h' \quad (2.37)$$

$$\mathbf{S}_h = \mathbf{C}_h \mathbf{S}_{h-1} \quad (2.38)$$

Algoritma SIMPLS selengkapnya ditunjukkan pada Gambar 2.2.



Gambar 2.2 Algoritma SIMPLS (De Jong, 1993)

Salah satu sifat penting dari PLS adalah menentukan jumlah variabel laten yang digunakan. Jumlah variabel laten ditentukan oleh perhitungan statistik yang menilai akurasi pendugaan, yaitu *Prediction Residual Sum of Square* (PRESS). Rumus untuk nilai PRESS dengan respon *multivariate* dapat ditulis seperti persamaan (2.39)

$$\text{PRESS} = \text{tr}[(\mathbf{Y} - \hat{\mathbf{Y}}_t)^T (\mathbf{Y} - \hat{\mathbf{Y}}_t)] \quad (2.39)$$

dimana,

\mathbf{Y} = matriks variabel respon

$\hat{\mathbf{Y}}_t$ = matriks dugaan respon tanpa pengamatan ke- t

Menurut Wulandari (2000), penentuan jumlah variabel laten ditentukan berdasarkan nilai PRESS terkecil, karena memberikan kestabilan lebih tinggi terhadap model bila terdapat amatan baru.

Ukuran kebaikan model yang digunakan untuk merepresentasikan kebaikan suatu prediksi dapat dilihat dari nilai koefisien determinasi. Berikut merupakan rumus untuk mendapatkan nilai koefisien determinasi.

$$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (2.40)$$

y_t = variabel respon

\hat{y}_t = variabel respon dugaan

\bar{y}_t = rata-rata variabel respon

2.4 Validasi Model

Validasi model adalah proses untuk mengetahui apakah model menghasilkan prediksi yang akurat. Validasi model bertujuan untuk melihat kemampuan model melakukan pendugaan terhadap data baru yang bukan bagian dari data penyusun model. Validasi model dilakukan dengan membagi data menjadi dua bagian yaitu, data *training* dan data *testing*. Data *training* digunakan untuk membangun model, sedangkan data *testing* digunakan untuk validasi model.

Menurut Shao dan Yadong (2004) dalam Sari (2013), *Root Mean Square Error of Prediction* (RMSEP) merupakan salah satu

perhitungan statistik yang dapat digunakan sebagai ukuran kebaikan hasil dugaan. Semakin kecil hasil RMSEP, maka semakin baik dugaan model yang dihasilkan. Rumus untuk mendapatkan RMSEP adalah sebagai berikut.

$$\text{RMSEP} = \sqrt{\frac{\sum_{t=1}^{n_{\text{pred}}} (Y_t - \hat{Y}_t)^2}{n_{\text{pred}}}} \quad (2.41)$$

dimana,

Y_t = variabel respon

\hat{Y}_t = variabel respon dugaan

n_{pred} = banyak data prediksi

Berdasarkan hasil verifikasi Bidang Analisa Meteorologi BMKG pada tahun 2004, kriteria nilai RMSEP disajikan pada Tabel 2.1.

Tabel 2.1 Kriteria Nilai RMSEP Suhu dan Kelembapan

Unsur	Nilai RMSEP	Kriteria
Suhu	0,0 – 0,4	Baik sekali
	0,5 – 0,8	Baik
	0,9 – 1,2	Sedang
	1,3 – 1,6	Buruk
	>1,6	Buruk sekali
Kelembapan	0,0 – 2,5	Baik sekali
	2,6 – 5,0	Baik
	5,1 – 7,5	Sedang
	7,6 – 10,0	Buruk
	>10,0	Buruk sekali

2.5 Ukuran Pengkoreksi Bias

Prakiraan yang dihasilkan oleh model NWP masih belum memuaskan karena masih terdapat bias yang cukup tinggi (BMKG, 2005). Oleh karena itu perlu diketahui seberapa besar model MOS dapat mengkoreksi bias dari model NWP. Persentase perbaikan model MOS terhadap model NWP dapat dihitung melalui *Percentage Improval* atau %IM (Davis, 2004). Semakin besar nilai

%IM, maka semakin baik pula model MOS dalam mengkoreksi bias dari prakiraan yang dihasilkan oleh model NWP. Berikut merupakan rumus %IM yang ditunjukkan pada persamaan (2.42).

$$\%IM = \frac{RMSEP_{NWP} - RMSEP_{MOS}}{RMSEP_{NWP}} \times 100\% \quad (2.42)$$

2.6 Numerical Weather Prediction (NWP)

NWP adalah program komputer yang menggambarkan persamaan numerik atmosfer dan perubahan kondisi atmosfer dalam satuan waktu tertentu (Al Yahyai, Charabi, dan Gastli, 2010). NWP menggunakan kemampuan komputer super tinggi untuk memprediksi kondisi cuaca yang akan datang. Menurut BMG (2007) dalam Ristanti (2009), model NWP dapat diklasifikasikan ke dalam empat kategori berdasarkan skala sistem atmosfer yang dihitung, yaitu sebagai berikut.

a. Model Klimatologi

Model ini disebut juga *General Circulation Models* (GCM). Model ini menggambarkan kondisi umum dari lapisan troposfir dan stratosfir dalam periode panjang.

b. Model Skala Sinoptik

Model ini banyak digunakan oleh banyak pusat operasional di dunia untuk menghitung prakiraan cuaca jangka menengah. Model ini dapat melingkupi domain global dan regional, tergantung pada aplikasi dan kemampuan komputasi di pusat meteorologi.

c. Model Skala Meso

Model ini digunakan untuk memprediksi perubahan cuaca lokal.

d. Model Khusus

Model ini digunakan untuk tujuan khusus seperti penyelidikan proses skala mikro dan arah turbulensi di atas gunung.

Selain itu, model NWP juga diklasifikasikan berdasarkan pada metode numerik yang digunakan sebagai berikut.

a. Model Spectral

Model spectral disebut juga harmonik *spherical* dalam aplikasi model global.

b. Model Elemen Terbatas

Model Elemen Terbatas digunakan dalam model komputasi dinamika fluida secara luas. Area model dibagi ke dalam banyak elemen atau volume.

c. Model Grid

Model grid membagi atmosfer dalam kubus atau *parcel* udara. Ukuran grid kotak atau jarak antara dua kotak menentukan resolusi model. Akurasi perkiraan model NWP pada prinsipnya akan meningkat jika resolusi model ditingkatkan.


Menurut Raible, Bishop, dan Fraedrich (1998), secara umum model-model NWP sudah cukup baik dalam melakukan peramalan jangka pendek. NWP dicatat pada grid (kombinasi lintang-bujur) tertentu dengan deskripsi sebagai berikut.

1. NWP diukur pada level tekanan tertentu, yaitu 1000 mb, 950 mb, 925 mb, 900 mb, 850 mb, 800 mb, 700 mb, 600 mb, 500 mb, 400 mb, 350 mb, 300 mb dan 200mb dan dapat diukur dengan level ketinggian permukaan, 2 meter, dan 10 meter di atas permukaan laut.
2. Ramalan NWP dilakukan dengan waktu tertentu, misal 3 atau 6 jam sekali.
3. NWP memiliki resolusi grid lintang bujur $0,5^\circ \times 0,5^\circ$ ($55,5 \times 55,5$)km² hingga $1^\circ \times 1^\circ$ (111×111)km². NWP diukur pada grid yang luas dengan ukuran lintang-bujur tertentu.

Berdasarkan skala tersebut, NWP akan memberikan informasi cuaca yang homogen pada daerah grid tersebut. Oleh karena itu, prakiraan NWP menghasilkan bias yang besar terutama untuk wilayah topografi dan tutupan vegetasi yang kompleks. Perbedaan NWP dengan kondisi nyata suatu wilayah diilustrasikan pada Gambar 2.4.

Gambar 2.4 menunjukkan bahwa model NWP menyederhanakan dan menghomogenkan kondisi permukaan dengan merepresentasikan permukaan bumi menjadi rangkaian

titik grid, padahal kondisi nyata permukaan bumi dan atmosfer di suatu tempat sangat beragam baik dalam domain spasial, temporal, dan ketinggian. Efek penting dalam skala kecil (seperti topografi) untuk cuaca lokal mungkin tidak tercakup dan tidak direpresentasikan dengan baik oleh model NWP, sehingga model NWP yang dihasilkan tidak sempurna dan hasil prakiraannya masih terdapat bias.




Gambar 2.4 Ilustrasi Kondisi Nyata (a) dengan Representasi NWP (b) (Linacre dan Greet, 2003)

Salah satu model aplikasi yang terintegrasi dengan NWP adalah model WRF-EMS. WRF-EMS merupakan salah satu turunan dari model WRF selain WRF-DA (*Data Assimilation*) dan WRF-Chem (*Chemistry*). Model ini dikembangkan oleh *National Oceanic and Atmospheric Administration (NOOA)* bekerjasama dengan *National Weather Service (NWS)*, *Forecast Decision Training Branch (FTDB)*, dan *Science Operations Officer and Training Resource Center (SOO/STCR)*. Menurut Rozumalski (2010), WRF-EMS menjadi salah satu model yang lengkap, *full-physics, state-of-the-science* dari produk NWP, serta merupakan gabungan dari dua model dinamis yang umum digunakan yaitu *Advanced Research WRF (ARW)* dari *National Center for Atmospheric Research (NCAR)* dan *Non-Hydrostatic Mesoscale Model (NMM)* dari *National Center for Environmental Research (NCER)*. Model ARW sering digunakan untuk penelitian, sedangkan model NMM digunakan untuk keperluan prediksi operasional. Kelebihan dari model WRF-EMS adalah model tersebut telah dirancang sedemikian rupa sehingga sangat *fleksibel*

dalam instalasi dan konfigurasinya yang membuat model WRF-EMS menjadi mudah dijalankan baik untuk tujuan penelitian maupun prakiraan *real-time*. Penggunaan model WRF-EMS terdiri atas tiga perintah sebagai berikut.

- ems_prep* berfungsi untuk menentukan data dan mengkonfigurasi waktu yang dijalankan.
- ems_run* berfungsi untuk menjalankan model.
- ems_post* berfungsi untuk menentukan *output* model (tahap akhir).

Proses dalam sistem WRF-EMS selengkapnya dapat dilihat pada Gambar 2.5.



Gambar 2.5 Diagram Alur Proses Sistem WRF-EMS (Rozumalski, 2010)

2.7 Suhu

Suhu atau temperatur udara merupakan suatu kondisi yang dapat dirasakan di permukaan bumi sebagai panas, sejuk, atau

dingin. Permukaan bumi menerima panas dari penyinaran matahari berupa radiasi gelombang elektromagnetik. Pengaruh langsung yang dirasakan oleh bumi sebagai akibat radiasi matahari adalah adanya perbedaan suhu di berbagai tempat. Menurut Utoyo (2009), faktor-faktor yang menyebabkan adanya perbedaan suhu adalah sebagai berikut.

a. Sudut datang sinar matahari

Sudut yang dibentuk oleh arah datangnya sinar matahari dengan permukaan bumi dapat menyebabkan adanya perbedaan suhu. Semakin tegak sudut datang sinar matahari, maka semakin kuat intensitas penyinaran matahari. Hal tersebut menyebabkan semakin tinggi suhu udara pada suatu daerah. Sebaliknya, apabila semakin miring sudut datang sinar matahari, maka semakin lemah intensitas penyinarannya dan suhu udara pada suatu daerah semakin rendah.

b. Lama waktu penyinaran

Semakin lama penyinaran matahari, maka semakin tinggi pula suhu udara di suatu daerah. Berikut adalah lama penyinaran matahari di beberapa garis lintang yang disajikan pada Tabel 2.2.

Tabel 2.2 Lama Penyinaran Matahari Maksimal Selama Musim Panas di Beberapa Garis Lintang

No.	Lintang	Waktu Penyinaran Maksimal (Periode Siang)
1.	0°	12 jam
2.	17°	13 jam
3.	41°	15 jam
4.	49°	16 jam
5.	63°	20 jam
6.	66½°	24 jam
7.	67½°	1 bulan
8.	90° (kutub)	6 bulan

c. Ketinggian tempat

Semakin tinggi suatu daerah dari permukaan laut, semakin rendah suhu udara di daerah tersebut. Rata-rata suhu udara akan

mengalami penurunan sekitar $0,5^{\circ}\text{C}$ - $0,6^{\circ}\text{C}$ setiap tempat yang mengalami kenaikan 100 meter. Hal tersebut dikenal sebagai gejala gradien termometrik. Berdasarkan hasil penelitian, rata-rata suhu udara harian di daerah pantai kawasan tropis seperti Indonesia adalah sekitar 26°C .

d. Kondisi geografis wilayah

Indonesia merupakan negara yang sebagian besar wilayahnya adalah kepulauan dan dikelilingi oleh laut. Hal tersebut menyebabkan perbedaan suhu udara harian di Indonesia tidak begitu tinggi. Berbeda halnya dengan, wilayah-wilayah yang berlokasi di tengah benua yang jauh dari laut, seperti daerah Asia Tengah. Perbedaan suhu udara antara siang dan malam di daerah tersebut sangatlah mencolok, seperti suhu udara yang sangat tinggi saat siang, namun pada malam hari sangat rendah bahkan sampai di bawah 0°C .

2.8 Kelembapan

Banyaknya uap air yang terkandung dalam sejumlah massa udara disebut dengan kelembapan udara. Menurut Utoyo (2009), kelembapan udara dapat dibagi menjadi tiga macam, yaitu sebagai berikut.

a. Kelembapan absolut atau densitas uap air

Kelembapan absolut biasanya ditunjukkan dengan angka perbandingan kandungan uap air dalam setiap unit volume udara. Satuan yang biasa digunakan adalah gram/m^3 atau gram/liter .

b. Kelembapan spesifik

Kelembapan spesifik merupakan perbandingan kandungan uap air dalam setiap satuan massa (satuan berat) udara dengan menggunakan satuan gram/kg .

c. Kelembapan relatif

Kelembapan relatif (nisbi) didefinisikan sebagai perbandingan tekanan uap air aktual dengan tekanan uap air maksimum yang dapat dicapai pada suhu udara dan tekanan udara yang sama.

(Halaman ini sengaja dikosongkan)

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Bagian Penelitian dan Pengembangan Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Pusat Jakarta, meliputi observasi cuaca permukaan dan data luaran *Numerical Weather Prediction* (NWP) model *Weather Research and Forecasting Environmental Modelling System* (WRF-EMS) dengan periode 2 Januari 2015 sampai dengan 10 Desember 2016. Lokasi yang digunakan dalam penelitian ini adalah 3 stasiun meteorologi di Indonesia, seperti yang disajikan pada Tabel 3.1.

Tabel 3.1 Lokasi Stasiun Pengamatan

No.	Nama Stasiun Pengamatan	Longitude	Lattitude
1.	Stasiun Juanda	106,656	-6,126
2.	Stasiun Soekarno Hatta	112,787	-7,380
3.	Stasiun Ngurah Rai	115,167	-8,748

3.2 Variabel Penelitian

3.2.1 Variabel Respon

Variabel respon yang digunakan dalam penelitian ini adalah unsur cuaca yang terdiri atas suhu maksimum (T_{\max}), suhu minimum (T_{\min}), dan kelembapan (RH).

3.2.2 Variabel Prediktor

Variabel prediktor yang digunakan dalam penelitian ini adalah data luaran NWP model WRF-EMS. Parameter NWP yang digunakan pada penelitian ini disajikan pada Tabel 3.2.


Tabel 3.2 Parameter NWP Model WRF-EMS

No.	Variabel	Satuan
1.	<i>Total Rainfall (totrain)</i>	mm/hari
2.	<i>Dew Point (dew)</i>	celcius
3.	<i>Wind Gust (windgust)</i>	m/s

Tabel 3.2 Parameter NWP Model WRF-EMS (Lanjutan)

No.	Variabel	Satuan
4.	<i>High Cloud (hicloud)</i>	%
5.	<i>Low Cloud (lowcloud)</i>	%
6.	<i>Middle Cloud (midcloud)</i>	%
7.	<i>Total Cloud (totcloud)</i>	%
8.	<i>Mean Sea Level Pressure (mslp)</i>	mb
9.	<i>Surface Pressure (surpres)</i>	mb
10.	<i>Relative Humidity (rhum)</i>	%
11.	<i>Specific Humidity (shum)</i>	kg/kg
12.	<i>Temperature (temp)</i>	celcius
13.	<i>U Wind (uwind)</i>	m/s
14.	<i>V Wind (vwind)</i>	m/s
15.	<i>Surface</i>	m

Parameter yang akan digunakan dari NWP model WRF-EMS adalah sebanyak 15 parameter yang telah ditentukan oleh ahli meteorologi pada masing-masing lokasi pengamatan. Masing-masing parameter tersebut diukur pada sembilan grid (3x3) pengukuran yang terdekat dari lokasi stasiun pengamatan. Berikut merupakan proyeksi pengukuran NWP dalam sembilan grid yang ditunjukkan pada Gambar 3.1. Titik berwarna merah menandakan grid yang paling dekat pada lokasi pengamatan, sedangkan titik berwarna hitam merupakan kombinasi grid di sekitar lokasi pengamatan.

**Gambar 3.1** Pengukuran NWP Model WRF-EMS dalam Grid 3 x 3

Definisi parameter NWP model WRF-EMS adalah sebagai berikut.

1. *Total Rainfall* adalah jumlah setiap produk dari kondensasi uap air di atmosfer yang jatuh karena gravitasi.
2. *Dew Point* adalah pengukuran titik embun yang dilakukan pada ketinggian 2 meter di atas permukaan laut.
3. *Wind Gust* adalah angin yang berkaitan dengan badaiguntur arah dan kecepatannya dapat berubah dengan cepat. Perubahan kecepatannya dapat besar dan dalam waktu yang singkat. Sesaat sesudah terjadi perubahan tersebut biasanya diikuti keadaan lengang atau tak ada angin.
4. *High cloud* adalah awan yang letaknya pada ketinggian lebih dari 8 km tetapi tidak sama disetiap wilayah.
5. *Low cloud* adalah awan yang terletak pada paras rendah kurang dari 2 km.
6. *Middle cloud* adalah awan yang terletak pada paras antara 2 – 8 km tetapi tidak sama disetiap wilayah.
7. *Total cloud* adalah awan yang letaknya diantara ketinggian kurang dari 2 – 8 km tetapi tidak sama disetiap wilayah.
8. *Mean Sea Level Pressure* adalah suhu rata-rata di atas permukaan laut.
9. *Surface Pressure* atau tekanan permukaan diukur berdasarkan tekanan gaya pada permukaan dengan luas tertentu. Alat pengukur tekanan udara disebut barometer. Tekanan udara berkurang dengan bertambahnya ketinggian.
10. *Relative Humidity* adalah nilai perbandingan antara tekanan uap air yang ada pada saat pengukuran dan besarnya tekanan uap air maksimum yang dapat dicapai pada suhu dan tekanan udara pada saat itu. Kelembapan relatif diukur pada ketinggian 2 meter di atas permukaan laut.
11. *Spesific Humidity* perbandingan antara massa uap air dan massa udara dalam tiap satuan volume udara yang diukur pada ketinggian 2 meter di atas permukaan laut.
12. *Temperature* atau suhu udara adalah derajat panas dan dingin udara di atmosfer yang diukur pada ketinggian 2 meter diatas

permukaan laut. Suhu udara memiliki hubungan berbanding terbalik dengan tekanan udara.

13. *U wind* adalah konvensi angin dari arah barat ke timur yang diukur pada ketinggian 10 meter diatas permukaan laut.
14. *V wind* adalah konvensi angin dari arah selatan ke utara yang diukur pada ketinggian 10 meter diatas permukaan laut.

3.3 Struktur Data

Struktur data untuk pengamatan di satu wilayah disajikan pada Tabel 3.2 berikut.

Tabel 3.2 Struktur Data Penelitian

Tanggal	Variabel Respon			Variabel Prediktor						
				X_1			...	X_{15}		
	Y_1	Y_2	Y_3	X_{11}	...	X_{19}	...	X_{151}	...	X_{159}
2/1/2015	*	*	*	$X_{1.11}$...	$X_{1.19}$...	$X_{1.151}$...	$X_{1.159}$
3/1/2015	$Y_{1.1}$	$Y_{1.2}$	$Y_{1.3}$	$X_{2.11}$...	$X_{2.19}$...	$X_{2.151}$...	$X_{2.159}$
4/1/2015	$Y_{2.1}$	$Y_{2.2}$	$Y_{2.3}$	$X_{3.11}$...	$X_{3.19}$...	$X_{3.151}$...	$X_{3.159}$
5/1/2015	$Y_{3.1}$	$Y_{3.2}$	$Y_{3.3}$	$X_{4.11}$...	$X_{4.19}$...	$X_{4.151}$...	$X_{4.159}$
6/1/2015	$Y_{4.1}$	$Y_{4.2}$	$Y_{4.3}$	$X_{5.11}$...	$X_{5.19}$...	$X_{5.151}$...	$X_{5.159}$
7/1/2015	$Y_{5.1}$	$Y_{5.2}$	$Y_{5.3}$	$X_{6.11}$...	$X_{6.19}$...	$X_{6.151}$...	$X_{6.159}$
8/1/2015	$Y_{6.1}$	$Y_{6.2}$	$Y_{6.3}$	$X_{7.11}$...	$X_{7.19}$...	$X_{7.151}$...	$X_{7.159}$
⋮	⋮	⋮	⋮	⋮	...	⋮	...	⋮	...	⋮
18/12/2016	$Y_{346.1}$	$Y_{346.2}$	$Y_{346.3}$	$X_{347.11}$...	$X_{347.19}$...	$X_{347.151}$...	$X_{347.159}$
19/12/2016	$Y_{347.1}$	$Y_{347.2}$	$Y_{347.3}$	$X_{348.11}$...	$X_{348.19}$...	$X_{348.151}$...	$X_{348.159}$
20/11/2016	$Y_{348.1}$	$Y_{348.2}$	$Y_{348.3}$	$X_{349.11}$...	$X_{349.19}$...	$X_{349.151}$...	$X_{349.159}$
21/11/2016	$Y_{349.1}$	$Y_{349.2}$	$Y_{349.3}$	$X_{350.11}$...	$X_{350.19}$...	$X_{350.151}$...	$X_{350.159}$
22/11/2016	$Y_{350.1}$	$Y_{350.2}$	$Y_{350.3}$	$X_{351.11}$...	$X_{351.19}$...	$X_{351.151}$...	$X_{351.159}$
23/11/2016	$Y_{351.1}$	$Y_{351.2}$	$Y_{351.3}$	$X_{352.11}$...	$X_{352.19}$...	$X_{352.151}$...	$X_{352.159}$
10/12/2016	$Y_{352.1}$	$Y_{352.2}$	$Y_{352.3}$	*	*	*	*	*	*	*

3.4 Langkah Analisis


Berikut ini merupakan langkah analisis yang dilakukan berdasarkan tujuan penelitian yang ingin dicapai.

1. *Pre-processing* atau proses penyiapan data.
 - a. Melakukan akumulasi data *Total Rainfall* perjam (selama 24 jam/hari) agar mendapatkan data *Total Rainfall* harian.
 - b. Melakukan perhitungan rata-rata pada data *Dew Point*, *Wind Gust*, *High Cloud*, *Low Cloud*, *Middle Cloud*, *Total Cloud*, *Mean Sea Level Pressure*, *Surface Pressure*, *Relative Humidity*, *Specific Humidity*, *Temperature*, *U Wind*, *V Wind*, dan *Surface Vis* perjam (selama 24 jam/hari) agar mendapatkan data harian.
 - c. Menyetarakan jumlah data NWP model WRF-EMS dengan data observasi cuaca permukaan berdasarkan waktu pengukuran.
 - d. Melakukan imputasi data apabila terdapat data kosong atau *missing value* pada data observasi dengan menggunakan nilai rata-rata dari nilai 1 hari sebelum dan 1 hari sesudahnya.
2. Melakukan standardisasi data pada data observasi cuaca dan data parameter NWP.
3. Membagi data menjadi dua bagian yaitu, data *training* dan data *testing* dengan 7 data terakhir digunakan sebagai data *testing*.
4. Mereduksi dimensi parameter NWP dalam 9 grid pengukuran menggunakan ICA dengan langkah sebagai berikut.
 - a. Memilih inisial vektor \mathbf{w}
 - b. Membentuk \mathbf{w}^+ (\mathbf{w} baru)
 - c. Menormalisasi nilai \mathbf{w}^+
 - d. Memeriksa konvergensi nilai \mathbf{w} setelah dinormalisasi dengan sebelum normalisasi. Jika tidak konvergen, kembali ke langkah 2.

5. Melakukan pemodelan MOS dengan tahapan sebagai berikut.
 - a. Menghitung pembobot
 - b. Menormalisasi pembobot (\mathbf{w}_h)
 - c. Menghitung komponen laten (\mathbf{t}_h)
 - d. Menghitung matriks loading
 - e. Memperbarui inisiasi iterasi
 - f. Menggabungkan nilai matrik **P**, **Q**, dan **W**
 - g. Membentuk matrik koefisien (**B**)
5. Melakukan validasi model menggunakan data *testing*.
6. Mengkoreksi bias model MOS terhadap model NWP.
7. Mendapatkan model terbaik.

3.5 Diagram Alir

Berdasarkan langkah analisis, diagram alir dalam penelitian ini adalah sebagai berikut.



Gambar 3.2 Diagram Alir Penelitian

BAB IV

ANALISIS & PEMBAHASAN

Bab ini membahas tentang penyusunan MOS menggunakan pendekatan *multivariate* respon. Pada bagian awal diuraikan mengenai analisis deskriptif unsur cuaca serta reduksi dimensi data NWP yang selanjutnya digunakan untuk membentuk model prakiraan. Bagian akhir, diuraikan validasi model untuk mengetahui kebaikan akurasi dan pengkoreksi bias model MOS.

4.1 Pemodelan SIMPLS

Ketiga unsur cuaca di tiga stasiun memiliki karakteristik yang berbeda-beda. Oleh karena itu, terlebih dahulu dilakukan analisis deskriptif terhadap unsur cuaca yang dijadikan respon yaitu T_{\max} , T_{\min} , dan RH di masing-masing stasiun.

4.1.1 Deskripsi Unsur Cuaca

Diantara ketiga unsur cuaca, kelembapan (RH) memiliki rata-rata harian yang cukup berbeda, sedangkan rata-rata harian suhu maksimum (T_{\max}) dan suhu minimum (T_{\min}) hampir sama di ketiga stasiun dalam dua tahun terakhir, seperti yang disajikan pada Tabel 4.1. Rata-rata T_{\max} berkisar antara 30°C - 33°C, rata-rata suhu minimum antara 24°C - 25°C, dan rata-rata kelembapan antara 77 – 81 persen.

Tabel 4.1 Nilai Rataan dan Standar Deviasi

Nama Stasiun	Unsur Cuaca	Rata-rata	Standar Deviasi
Juanda	T_{\max} (°C)	31,93	0,98
	T_{\min} (°C)	24,60	1,30
	RH (%)	77,14	6,16
Soekarno Hatta	T_{\max} (°C)	32,11	1,22
	T_{\min} (°C)	24,08	0,84
	RH (%)	77,93	5,83

Tabel 4.1 Nilai Rataan dan Standar Deviasi (Lanjutan)

Nama Stasiun	Unsur Cuaca	Rata-rata	Standar Deviasi
Ngurah Rai	T_{\max} ($^{\circ}\text{C}$)	30,54	0,94
	T_{\min} ($^{\circ}\text{C}$)	24,48	1,31
	RH (%)	80,22	3,69

Rata-rata suhu maksimum harian terendah dan tertinggi diantara tiga stasiun terdapat pada Stasiun Soekarno Hatta, yaitu sebesar 24,08 dan 32,11 $^{\circ}\text{C}$. Sementara itu, rata-rata kelembapan yang paling tinggi terdapat pada Stasiun Ngurah Rai dengan nilai sebesar 80,22 persen, sedangkan rata-rata kelembapan terendah terdapat pada Stasiun Juanda dengan nilai sebesar 77,14 persen.

Standar deviasi suhu maksimum dan suhu minimum relatif hampir sama. Untuk suhu maksimum berkisar antara 0,9 - 1,3; suhu minimum antara 0,8 – 1,4; sedangkan standar deviasi kelembapan memiliki nilai antara 3 - 7. Untuk keragaman data pada suhu maksimum dan minimum di tiga stasiun cukup rendah, sedangkan keragaman data untuk kelembapan cukup tinggi yang dapat dilihat dari nilai standar deviasinya.

Masing-masing variabel NWP di sembilan grid yang dijadikan sebagai variabel prediktor juga memiliki karakteristik yang berbeda. Analisis deskriptif pada data NWP dapat dilihat dari rata-rata dan standar deviasinya. Analisis deskriptif data NWP pada Stasiun Juanda, Soekarno Hatta, dan Ngurah Rai disajikan pada Lampiran 7-9.

Setelah mendeskripsikan variabel respon unsur cuaca, langkah selanjutnya yaitu pra-pemrosesan data NWP menggunakan ICA. Namun, salah satu tahap yang harus dilakukan sebelum melakukan pra-pemrosesan data NWP, terlebih dahulu dilakukan standarisasi data, baik variabel respon yaitu data observasi T_{\max} , T_{\min} , dan RH maupun variabel prediktor yaitu data NWP. Standarisasi dilakukan dengan tujuan untuk meminimalkan perbedaan skala pengukuran antar variabel. Standarisasi untuk variabel respon menggunakan rata-rata dan standar deviasi pada Tabel 4.1, sedangkan standarisasi untuk variabel prediktor

menggunakan rata-rata dan standar deviasi pada Lampiran 7-9. Selanjutnya, data dibagi menjadi dua bagian, yaitu data *training* dan data *testing*. Sebanyak 345 data digunakan sebagai data *training* yaitu untuk membangun model menggunakan SIMPLS, sedangkan 7 data terakhir digunakan sebagai data *testing* untuk validasi model.

4.1.2 Reduksi Dimensi Data NWP

Data NWP diambil dalam 9 grid pengukuran di setiap lokasi untuk masing-masing variabel. Banyaknya variabel tersebut mengakibatkan data luaran NWP memiliki dimensi yang tinggi, sehingga dilakukan reduksi dimensi menggunakan metode ICA. Penentuan banyaknya komponen independen yang terbentuk dapat dilihat dari nilai eigen dan prosentase varians kumulatif. Nilai eigen dan prosentase varians kumulatif dari variabel *Dew Point* diperoleh hasil sebagai berikut.

Tabel 4.2 Nilai Eigen dan Varians Kumulatif di Tiga Stasiun

IC ke-	Juanda		Soekarno Hatta		Ngurah Rai	
	Nilai Eigen	Kum. varians (%)	Nilai Eigen	Kum. varians (%)	Nilai Eigen	Kum. varians (%)
1	8,65*	96,14	8,47*	94,15	8,45*	93,92
2	0,24	98,83	0,46	99,21	0,48	99,23
3	0,07	99,57	0,04	99,68	0,03	99,61
4	0,03	99,87	0,02	99,88	0,02	99,83
5	0,01	99,95	0,01	99,97	0,01	99,94
6	0,00	99,97	0,00	99,98	0,00	99,99
7	0,00	99,99	0,00	99,99	0,00	100,00
8	0,00	100,00	0,00	100,00	0,00	100,00
9	0,00	100,00	0,00	100,00	0,00	100,00

Ket : *komponen dengan nilai eigen lebih dari 1

Penentuan jumlah komponen yang terbentuk dalam ICA yaitu dengan memilih komponen yang memiliki nilai eigen lebih dari satu. Berdasarkan Tabel 4.2, nilai eigen yang terbentuk di

Stasiun Juanda dengan jumlah komponen 1 adalah sebesar 8,65 dengan varians kumulatif sebesar 96,14%. Oleh karena itu, penentuan jumlah IC sebanyak 1 telah memenuhi syarat. Langkah serupa juga dilakukan pada variabel NWP lain di semua stasiun pengamatan, sehingga didapatkan jumlah IC yang optimal dengan nilai eigen lebih dari satu. Penentuan jumlah komponen di Stasiun Soekarno Hatta dan Stasiun Ngurah Rai disajikan pada Lampiran 10 dan 11. Berikut ini disajikan nilai eigen dan varians kumulatif di setiap variabel NWP di Stasiun Juanda.

Tabel 4.3 Jumlah Komponen Variabel NWP di Stasiun Juanda

No.	Variabel	Jumlah IC	Nilai Eigen	Kum. varians (%)
1.	<i>Dew Point</i>	1	8,65	96,14
2.	<i>High Cloud</i>	1	8,32	92,40
3.	<i>Total Rainfall</i>	2	6,32; 1,36	85,32
4.	<i>Low Cloud</i>	2	5,48; 1,87	81,71
5.	<i>Middle Cloud</i>	1	8,09	89,90
6.	<i>Mean Sea Level Pressure</i>	1	8,96	99,56
7.	<i>Relative Humidity</i>	1	7,90	87,74
8.	<i>Specific Humidity</i>	1	8,57	95,27
9.	<i>Surface Pressure</i>	1	8,93	99,22
10.	<i>Surface</i>	2	7,00; 1,24	91,59
11.	<i>Temperature</i>	2	6,55; 2,02	95,26
12.	<i>Total Cloud</i>	1	8,21	91,21
13.	<i>U Wind</i>	1	8,88	98,68
14.	<i>V Wind</i>	2	5,82; 2,43	91,69
15.	<i>Windgust</i>	1	7,69	85,47

Hampir semua variabel membentuk jumlah komponen sebanyak 1, kecuali variabel *Total Rainfall*, *Low Cloud*, *Surface*,

Temperature, dan *V wind* membentuk jumlah komponen sebanyak 2 seperti yang disajikan pada Tabel 4.3. Jumlah komponen yang terbentuk dari reduksi dimensi menggunakan ICA pada stasiun Juanda adalah sebanyak 20.

Selanjutnya, jumlah komponen yang terbentuk melalui proses ICA pada semua variabel NWP akan digunakan sebagai variabel prediktor dalam pemodelan MOS menggunakan SIMPLS.

4.1.3 Penentuan Jumlah Komponen Optimal

Sebelum melakukan pemodelan SIMPLS, terlebih dahulu menentukan jumlah maksimum komponen yang dapat digunakan untuk membangkitkan model prakiraan cuaca sebanyak 20 komponen pada stasiun Juanda. Kemudian, dilakukan proses validasi silang di setiap iterasi yang akan menghasilkan nilai PRESS. Nilai PRESS ini digunakan sebagai dasar pemilihan jumlah komponen yang optimal untuk suatu model. Model dengan nilai PRESS terkecil merupakan model dengan jumlah komponen yang optimal. Tabel 4.4 menunjukkan nilai PRESS di setiap iterasi dalam proses pemodelan SIMPLS 20 komponen model *multivariate* T_{\max} , T_{\min} , dan RH di Stasiun Juanda.

Tabel 4.4 Nilai PRESS yang Terbentuk di Stasiun Juanda

Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
1.	1,337	11.	1,072
2.	1,180	12.	1,068
3.	1,098	13.	1,060
4.	1,076	14.	1,059
5.	1,067	15.	1,059
6.	1,067	16.	1,063
7.	1,067	17.	1,064
8.	1,071	18.	1,063
9.	1,071	19.	1,063
10.	1,076	20.	1,066

Nilai PRESS terkecil dalam proses tersebut terdapat pada model T_{\max} , T_{\min} , dan RH dengan 14 komponen dan nilai PRESS sebesar 1,059. Model dengan 14 komponen tersebut dipilih dan akan digunakan untuk menduga model T_{\max} , T_{\min} , dan RH dengan regresi SIMPLS pada stasiun Juanda. Nilai PRESS selengkapnya untuk Stasiun Soekarno Hatta dan Stasiun Ngurah Rai di setiap tahapan iterasi disajikan pada Lampiran 12 dan 13. Jumlah komponen optimal untuk pemodelan SIMPLS di Stasiun Juanda, Soekarno Hatta, dan Ngurah Rai disajikan pada Tabel 4.5.

Tabel 4.5 Jumlah Komponen Optimal dan Nilai PRESS di Tiga Stasiun

Stasiun	Jumlah Komponen	Nilai PRESS Terendah
Juanda	14	1,059
Soekarno Hatta	4	1,202
Ngurah Rai	6	1,298

Setelah diperoleh jumlah komponen yang optimal pada tiap stasiun, langkah berikutnya adalah melakukan pemodelan SIMPLS untuk prakiraan model T_{\max} , T_{\min} , dan RH.

4.1.4 Menghitung Pembobot SIMPLS

Matriks W adalah matrik *weight* (pembobot) berukuran $p \times c$ yang didapatkan dari hasil penggabungan vektor-vektor pembobot dari setiap komponen yang diekstraksi. Komponen yang diekstraksi merupakan jumlah komponen optimal yang ditetapkan sebelumnya. Dalam menyusun model T_{\max} , T_{\min} , dan RH di Stasiun Juanda didapatkan jumlah komponen yang diekstraksi sebanyak 14. Matriks W diperoleh dari rumus $w_h = (X'Y)_h - q_h$ yang telah dinormalisasi. w_h yang diperoleh kemudian ditempatkan pada matriks W sebagai kolom. Matriks W yang terbentuk berukuran 20×14 . Hasil pembobotan tersebut disajikan pada Tabel 4.6. Hasil pembobotan variabel prediktor untuk stasiun Soekarno Hatta dan stasiun Ngurah Rai disajikan pada Lampiran 14 dan 15.

Tabel 4.6 Nilai Pembobot X

No.	Variabel	W1	W2	...	W13	W14
1.	IC.dew	-0,0031	0,0050	...	0,0030	0,0174
2.	IC.hicloud	-0,0008	-0,0027	...	0,0003	-0,0041
3.	IC1.totrain	-0,0014	-0,0030	...	0,0200	-0,0163
4.	IC2.totrain	0,0000	0,0005	...	0,0222	0,0168
5.	IC1.lowcloud	-0,0010	-0,0025	...	-0,0244	-0,0025
6.	IC2.lowcloud	0,0002	0,0002	...	-0,0055	-0,0067
7.	IC.midcloud	-0,0017	-0,0035	...	-0,0070	0,0111
8.	IC.mslp	0,0018	-0,0014	...	0,0044	0,0058
9.	IC.rhum	-0,0028	0,0007	...	-0,0110	-0,0013
10.	IC.shum	-0,0031	0,0049	...	-0,0058	-0,0007
11.	IC.surpres	0,0020	-0,0007	...	-0,0085	-0,0075
12.	IC1.survis	0,0009	0,0025	...	-0,0073	-0,0002
13.	IC2.survis	0,0002	0,0002	...	0,0057	0,0194
14.	IC1.temp	0,0008	0,0053	...	-0,0057	0,0061
15.	IC2.temp	-0,0011	0,0029	...	-0,0037	-0,0426
16.	IC.totcloud	-0,0014	-0,0036	...	-0,0029	0,0068
17.	IC.uwind	-0,0018	-0,0025	...	-0,0194	-0,0161
18.	IC1.vwind	0,0021	-0,0021	...	-0,0298	-0,0048
19.	IC2.vwind	0,0004	0,0016	...	-0,0466	-0,0372
20.	IC.windgust	0,0017	-0,0015	...	0,0022	-0,0055

4.1.5 Membentuk X-scores

X-scores merupakan matriks komponen **T** yang memiliki keterkaitan erat terhadap variabel prediktor. Matriks **T** merupakan gabungan dari vektor **t** yang diperoleh dari perhitungan $T=XW$, dimana matriks **X** merupakan matriks prediktor dari hasil ICA dan matriks **W** merupakan matriks pembobot yang telah didapatkan pada subbab sebelumnya. Matriks **X** berukuran $n \times p$, dimana n merupakan banyaknya observasi dan p merupakan banyaknya prediktor, sehingga matriks **X** berukuran 345×20 . Karena matriks

W berukuran 20×14 , maka matriks **T** berukuran 345×14 . Komponen matriks **T** yang merupakan nilai *X-scores* pemodelan SIMPLS di Stasiun Juanda disajikan pada Tabel 4.7.

Tabel 4.7 Nilai *X-scores*

n	t₁	t₂	...	t₁₃	t₁₄
1.	0,0700	0,0350	...	0,1341	0,0666
2.	0,0646	0,0046	...	-0,0262	-0,0052
3.	0,0763	0,0471	...	-0,0448	-0,0759
4.	0,0293	0,0554	...	-0,0923	-0,0963
5.	-0,0054	0,0148	...	-0,0978	-0,0456
6.	0,0250	0,0148	...	-0,1054	-0,0343
7.	0,0090	0,0283	...	-0,0691	0,0229
8.	0,0257	0,0407	...	0,0830	0,0718
9.	0,0333	-0,0104	...	-0,0102	0,0136
10.	0,0539	-0,0500	...	-0,0993	-0,0616
11.	0,1187	0,0871	...	-0,1820	-0,1217
12.	0,0712	0,0411	...	0,1086	-0,1158
13.	0,0772	0,0577	...	0,0131	-0,0832
14.	0,0498	0,0238	...	0,1008	-0,0716
15.	0,0787	0,0677	...	0,1954	-0,1823
⋮	⋮	⋮	⋮	⋮	⋮
339.	-0,0135	-0,0485	...	0,0198	0,0418
340.	-0,0337	-0,0312	...	-0,0140	0,0478
341.	-0,0025	-0,0638	...	0,0170	0,0095
342.	-0,0002	-0,0879	...	0,0456	0,0024
343.	0,0059	-0,0118	...	0,0124	-0,0663
344.	0,0028	-0,0336	...	0,1175	-0,0753
345.	0,0488	-0,0410	...	-0,0304	-0,0181

4.1.6 Membentuk Matriks Faktor *Loadings* untuk X

Matriks faktor *loadings* untuk X merupakan matriks komponen **P**. Matriks komponen **P** merupakan gabungan vektor **p** yang diperoleh dari perhitungan $\mathbf{X}=\mathbf{TP}'+\mathbf{F}$. Matriks **P** didapatkan dengan cara iterasi. Setiap komponen dalam matriks **P** diperoleh dari rumus $\mathbf{p}_h = \mathbf{M}_{h-1}\mathbf{w}_h$. Matriks **P** yang didapat berukuran $p \times c$, dimana p merupakan banyaknya prediktor dan c adalah jumlah komponen optimal yang diekstraksi ($h=1,2,3,...,14$), sehingga matriks **P** berukuran 20×14 . Matriks faktor *loadings* untuk X disajikan pada Tabel 4.8.

Tabel 4.8 Matriks Faktor *Loadings* untuk X

No.	Variabel	p1	p2	...	p13	p14
1.	IC.dew	-47,3168	22,0382	...	-2,6530	1,4780
2.	IC.hicloud	-24,6061	-28,6887	...	-2,5019	-0,9526
3.	IC1.totrain	-30,7907	-24,7976	...	6,6703	-6,0091
4.	IC2.totrain	1,2371	-0,2154	...	11,5505	1,2419
5.	IC1.lowcloud	-23,2285	-19,3326	...	-13,0744	0,7081
6.	IC2.lowcloud	3,1424	1,1667	...	-10,4095	1,0896
7.	IC.midcloud	-35,6895	-31,5244	...	0,2563	4,7353
8.	IC.mslp	34,2015	-11,7355	...	-2,4077	1,1117
9.	IC.rhum	-47,0664	4,0835	...	-1,0574	5,3249
10.	IC.shum	-47,7681	21,7300	...	-2,2640	0,9660
11.	IC.surpres	37,8298	-8,3077	...	-1,6762	-1,0769
12.	IC1.survis	24,0459	27,7692	...	-4,7369	1,4529
13.	IC2.survis	2,2751	0,1926	...	-8,2995	2,6558
14.	IC1.temp	16,5870	19,4118	...	-0,4698	4,4488
15.	IC2.temp	-14,9732	12,0857	...	-1,3860	-10,6800
16.	IC.totcloud	-34,7085	-34,3064	...	-2,8571	1,8948
17.	IC.uwind	-40,1397	-18,7024	...	1,7954	-2,5626
18.	IC1.vwind	33,4343	-11,4929	...	-8,9656	4,6554
19.	IC2.vwind	9,0664	10,7100	...	0,6227	-5,9376
20.	IC.windgust	27,0556	-18,9343	...	4,3167	-2,6573

4.1.7 Membentuk Matriks Faktor *Loadings* untuk Y

Matriks faktor *loadings* untuk Y merupakan matriks **Q**. Matriks komponen **Q** merupakan gabungan vektor **q** yang diperoleh dari perhitungan $Y=TQ'+E$. Matriks **Q** diperoleh dengan cara iterasi. Setiap komponen dalam matriks **Q** didapatkan dari rumus $q_h = S_{h-1}^T w_h$. Matriks **Q** yang didapat berukuran $q \times c$, dimana q merupakan banyaknya respon dan c merupakan jumlah komponen optimal yang diekstrak, sehingga matriks **Q** berukuran 3×14 . Berikut merupakan matriks **Q** pada Stasiun Juanda yang disajikan pada Tabel 4.9.

Tabel 4.9 Matriks Faktor *Loadings* untuk Y

No.	Variabel	q1	q2	...	q13	q14
1.	T _{max}	0,3271	-5,4684	...	0,8255	0,5256
2.	T _{min}	6,2615	-9,7059	...	-0,2513	-0,5721
3.	RH	14,8609	-0,6318	...	-1,3080	-0,4684

4.1.8 Menghitung Koefisien Regresi

Matriks koefisien regresi (**B**) didapatkan dari persamaan $B = W(T'T)^{-1}T'Y$ atau $B=WQ'$. Matriks **W** merupakan matriks pembobot SIMPLS yang berukuran 20×14 . Matriks **Q** merupakan matriks faktor *loadings* untuk Y yang berukuran 3×14 , sehingga matriks Q^T berukuran 14×3 . Dengan demikian, matriks **B** berukuran 20×14 . Komponen matriks koefisien regresi SIMPLS untuk Stasiun Juanda disajikan pada Tabel 4.10.

Tabel 4.10 Koefisien Regresi SIMPLS

No.	Variabel	T _{max}	T _{min}	RH
1.	IC.dew	-0,0496	-0,1639	-0,0536
2.	IC.hicloud	0,0042	-0,0089	0,0330
3.	IC1.totrain	0,1340	0,1493	-0,1068
4.	IC2.totrain	-0,0154	-0,1400	-0,0296
5.	IC1.lowcloud	0,0692	0,0213	-0,0161
6.	IC2.lowcloud	-0,0253	-0,0149	0,0209

Tabel 4.10 Koefisien Regresi SIMPLS (Lanjutan)

No.	Variabel	T _{max}	T _{min}	RH
7.	IC.midcloud	-0,0196	-0,0056	-0,0746
8.	IC.mslp	0,0437	0,0569	-0,0230
9.	IC.rhum	0,0519	0,0418	0,0111
10.	IC.shum	-0,0837	-0,1478	-0,0198
11.	IC.surpres	-0,1052	-0,0708	0,0660
12.	IC1.survis	0,1296	0,1014	-0,1055
13.	IC2.survis	-0,0532	-0,0770	0,0018
14.	IC1.temp	-0,2149	-0,0769	0,0889
15.	IC2.temp	-0,1089	-0,0850	-0,0328
16.	IC.totcloud	0,0207	-0,0011	-0,0365
17.	IC.uwind	-0,2071	0,0618	0,1279
18.	IC1.vwind	-0,0974	0,0356	0,1640
19.	IC2.vwind	-0,1286	0,0330	0,2325
20.	IC.windgust	-0,0029	-0,0839	0,0552

4.1.9 Menyusun Model SIMPLS

Model prediksi yang disusun berdasarkan koefisien pada Tabel 4.10 di Stasiun Juanda disajikan pada Tabel 4.11 sebagai berikut.

Tabel 4.11 Model Prediksi dengan SIMPLS

$\hat{y}_{T_{\max}(t)} = -0,0496 \text{ IC.dew}_{(t-1)} + 0,0042 \text{ IC.hicloud}_{(t-1)} + 0,1340$ $\text{IC1.totrain}_{(t-1)} - 0,0154 \text{ IC2.totrain}_{(t-1)} + 0,0692$ $\text{IC1.lowcloud}_{(t-1)} - 0,0253 \text{ IC2.lowcloud}_{(t-1)} - 0,0196$ $\text{IC.midcloud}_{(t-1)} + 0,0437 \text{ IC.mslp}_{(t-1)} + 0,0519 \text{ IC.rhum}_{(t-1)}$ $- 0,0837 \text{ IC.shum}_{(t-1)} - 0,1052 \text{ IC.surpres}_{(t-1)} + 0,1296$ $\text{IC1.survis}_{(t-1)} - 0,0532 \text{ IC2.survis}_{(t-1)} - 0,2149 \text{ IC1.temp}_{(t-1)}$ $- 0,1089 \text{ IC2.temp}_{(t-1)} + 0,0207 \text{ IC.totcloud}_{(t-1)} - 0,2071$ $\text{IC.uwind}_{(t-1)} - 0,0974 \text{ IC1.vwind}_{(t-1)} - 0,1286 \text{ IC2.vwind}_{(t-1)}$ $- 0,0029 \text{ IC.windgust}_{(t-1)}$

$$\begin{aligned} \hat{y}_{T_{\min(t)}} = & -0,1639 \text{ IC.dew}_{(t-1)} - 0,0089 \text{ IC.hicloud}_{(t-1)} + 0,1493 \\ & \text{IC1.totrain}_{(t-1)} - 0,1400 \text{ IC2.totrain}_{(t-1)} + 0,0213 \\ & \text{IC1.lowcloud}_{(t-1)} - 0,0149 \text{ IC2.lowcloud}_{(t-1)} - 0,0056 \\ & \text{IC.midcloud}_{(t-1)} + 0,0569 \text{ IC.mslp}_{(t-1)} + 0,0418 \text{ IC.rhum}_{(t-1)} \\ & - 0,1478 \text{ IC.shum}_{(t-1)} - 0,0708 \text{ IC.surpres}_{(t-1)} + 0,1014 \\ & \text{IC1.survis}_{(t-1)} - 0,0770 \text{ IC2.survis}_{(t-1)} - 0,0769 \text{ IC1.temp}_{(t-1)} \\ & - 0,0850 \text{ IC2.temp}_{(t-1)} - 0,0011 \text{ IC.totcloud}_{(t-1)} + 0,0618 \\ & \text{IC.uwind}_{(t-1)} + 0,0356 \text{ IC1.vwind}_{(t-1)} + 0,0330 \text{ IC2.vwind}_{(t-1)} \\ & - 0,0839 \text{ IC.windgust}_{(t-1)} \end{aligned}$$

$$\begin{aligned} \hat{y}_{RH(t)} = & -0,0536 \text{ IC.dew}_{(t-1)} + 0,0330 \text{ IC.hicloud}_{(t-1)} - 0,1068 \\ & \text{IC1.totrain}_{(t-1)} - 0,0296 \text{ IC2.totrain}_{(t-1)} - 0,0161 \\ & \text{IC1.lowcloud}_{(t-1)} + 0,0209 \text{ IC2.lowcloud}_{(t-1)} - 0,0746 \\ & \text{IC.midcloud}_{(t-1)} - 0,0230 \text{ IC.mslp}_{(t-1)} + 0,0111 \text{ IC.rhum}_{(t-1)} \\ & - 0,0198 \text{ IC.shum}_{(t-1)} + 0,0660 \text{ IC.surpres}_{(t-1)} - 0,1055 \\ & \text{IC1.survis}_{(t-1)} + 0,0018 \text{ IC2.survis}_{(t-1)} + 0,0889 \text{ IC1.temp}_{(t-1)} \\ & - 0,0328 \text{ IC2.temp}_{(t-1)} - 0,0365 \text{ IC.totcloud}_{(t-1)} + 0,1279 \\ & \text{IC.uwind}_{(t-1)} + 0,1640 \text{ IC1.vwind}_{(t-1)} + 0,2325 \text{ IC2.vwind}_{(t-1)} \\ & + 0,0552 \text{ IC.windgust}_{(t-1)} \end{aligned}$$

Model prediksi yang terbentuk pada Tabel 4.11 masih dalam bentuk komponen independen, sehingga harus dikembalikan ke dalam bentuk variabel di sembilan grid dengan cara mengalikan variabel komponen independen dengan masing-masing *eigenvector*-nya. Matriks *eigenvector* berukuran $s \times k$, dimana s merupakan banyak grid dan k adalah banyak komponen independen. Matriks *eigenvector* untuk masing-masing komponen adalah sebagai berikut.

$$e = \begin{bmatrix} -0,333 & -0,317 & \dots & 0,536 & -0,307 \\ -0,337 & -0,329 & \dots & 0,466 & -0,344 \\ -0,336 & -0,334 & \dots & -0,028 & -0,331 \\ -0,336 & -0,336 & \dots & 0,512 & -0,322 \\ -0,339 & -0,340 & \dots & -0,008 & -0,357 \\ -0,324 & -0,329 & \dots & -0,253 & -0,330 \\ -0,336 & -0,342 & \dots & -0,055 & -0,323 \\ -0,337 & -0,342 & \dots & -0,291 & -0,345 \\ -0,323 & -0,331 & \dots & -0,282 & -0,339 \end{bmatrix}$$

Model prediksi yang dikembalikan ke dalam bentuk variabel sembilan grid disajikan pada Lampiran 24. Sementara, untuk Stasiun Soekarno Hatta dan Stasiun Ngurah Rai selengkapnya disajikan pada Lampiran 25 dan 26. Namun, variabel yang terbentuk masih dalam bentuk standarisasi, sehingga perlu dikembalikan ke dalam bentuk awal dengan cara dikalikan dengan standar deviasi dan ditambah dengan rata-rata yang terdapat pada Tabel 4.1.

R^2 merupakan nilai yang merepresentasikan kebaikan model SIMPLS untuk data *training*. Nilai R^2 untuk tiga stasiun selengkapnya disajikan pada Tabel 4.12 sebagai berikut.

Tabel 4.12 Nilai R^2 di Tiga Stasiun		
Nama Stasiun	Variabel	R^2 (%)
Juanda	T_{\max}	37,41
	T_{\min}	56,44
	RH	71,31
Soekarno Hatta	T_{\max}	34,31
	T_{\min}	26,81
	RH	51,50
Ngurah Rai	T_{\max}	58,79
	T_{\min}	31,92
	RH	25,52

Tabel 4.12 menunjukkan bahwa nilai R^2 untuk pemodelan T_{\max} berkisar antara 34 – 59 persen, pemodelan T_{\min} berkisar antara 26 – 57 persen, dan pemodelan RH antara 25 – 72 persen. Nilai R^2 untuk pemodelan T_{\max} di stasiun Juanda sebesar 37,41%. Artinya, sebesar 37,41% variansi suhu maksimum dapat dijelaskan dalam model, sedangkan sisanya sebesar 62,59% dijelaskan oleh faktor-faktor lain yang tidak termasuk dalam model.

4.2 Validasi Model

Validasi model digunakan untuk melihat kemampuan model SIMPLS melakukan pendugaan terhadap data baru yang bukan bagian dari data penyusun model. Setelah mendapatkan model, dilakukan penghitungan nilai prediksi. Nilai prediksi T_{\max} , T_{\min} , dan RH di Stasiun Juanda disajikan pada Tabel 4.13, sementara nilai prediksi untuk Stasiun Soekarno Hatta dan Stasiun Ngurah Rai disajikan pada Lampiran 27 dan 28.

Tabel 4.13 Nilai Prediksi di Stasiun Juanda

n	T_{\max}		T_{\min}		RH	
	y	\hat{y}	y	\hat{y}	y	\hat{y}
346.	33,20	33,25	24,70	25,32	77,62	82,14
347.	34,00	33,09	26,00	26,05	74,02	75,59
348.	33,80	32,98	26,00	26,08	76,86	77,57
349.	33,40	33,09	26,80	25,78	78,03	75,85
350.	31,80	33,26	25,60	25,90	81,80	76,80
351.	32,00	32,65	26,40	25,23	84,91	84,33
352.	31,40	32,13	25,80	24,64	76,99	85,34

Setelah didapatkan nilai prediksi, validasi model dilakukan dengan menghitung nilai RMSEP pada data *testing* dengan data observasi yang disajikan pada Tabel 4.14.

Tabel 4.14 Nilai RMSEP Model SIMPLS

Nama Stasiun	Variabel	Nilai RMSEP	Kriteria RMSEP
Juanda	T_{\max}	0,8919	Baik
	T_{\min}	0,7790	Baik
	RH	4,1944	Baik
Soekarno Hatta	T_{\max}	1,0510	Sedang
	T_{\min}	0,8606	Baik
	RH	3,4195	Baik

Tabel 4.14 Nilai RMSEP Model SIMPLS (Lanjutan)


Nama Stasiun	Variabel	Nilai RMSEP	Kriteria RMSEP
Ngurah Rai	T_{\max}	1,1142	Sedang
	T_{\min}	1,4771	Buruk
	RH	4,2615	Baik

Nilai RMSEP untuk T_{\max} berkategori **baik** di Stasiun Juanda, sedangkan RMSEP T_{\max} di Stasiun Soekarno Hatta dan Ngurah Rai berkategori **sedang**. Untuk nilai RMSEP pada unsur cuaca T_{\min} berkategori **baik** di Stasiun Juanda dan Soekarno Hatta. Namun, nilai RMSEP T_{\min} di Stasiun Ngurah Rai berkategori **buruk**. Hal tersebut dikarenakan waktu pengamatan NWP pada data *testing* terakhir memiliki jarak yang jauh dengan waktu pengamatan sebelumnya, sehingga terindikasi adanya pola cuaca yang tidak *tercapture* oleh model. Pemodelan SIMPLS berkategori **baik** apabila digunakan untuk memodelkan RH di tiga stasiun karena menghasilkan RMSEP yang tergolong kecil.


Untuk mendukung validasi model, dapat dilihat pada Tabel 4.15 yang menyajikan hasil prediksi data observasi, hasil prediksi SIMPLS, dan hasil prediksi NWP. Visualisasi perbandingan hasil dugaan data observasi, hasil prediksi SIMPLS, dan hasil prediksi NWP disajikan pada Gambar 4.1, 4.2, dan 4.3

Tabel 4.15 Nilai Prediksi Model SIMPLS dengan NWP dan Observasi


n	T_{\max}			T_{\min}			RH		
	y	\hat{y}_{SIMPLS}	\hat{y}_{NWP}	y	\hat{y}_{SIMPLS}	\hat{y}_{NWP}	y	\hat{y}_{SIMPLS}	\hat{y}_{NWP}
346.	33,20	33,25	43,50	24,70	25,32	25,24	77,62	82,14	60,74
347.	34,00	33,09	42,86	26,00	26,05	25,29	74,02	75,59	63,12
348.	33,80	32,98	44,40	26,00	26,08	25,32	76,86	77,57	61,58
349.	33,40	33,09	44,29	26,80	25,78	24,75	78,03	75,85	62,11
350.	31,80	33,26	44,42	25,60	25,90	24,50	81,80	76,80	68,14
351.	32,00	32,65	44,89	26,40	25,23	24,37	84,91	84,33	70,07
352.	31,40	32,13	41,98	25,80	24,64	23,74	76,99	85,34	72,91



Gambar 4.1 Perbandingan Nilai Dugaan T_{max} pada Data Observasi, SIMPLS dan NWP



Gambar 4.2 Perbandingan Nilai Dugaan T_{min} pada Data Observasi, SIMPLS dan NWP



Gambar 4.3 Perbandingan Nilai Dugaan RH pada Data Observasi, SIMPLS dan NWP

Gambar 4.1, 4.2, dan 4.3, menunjukkan hasil dugaan SIMPLS yang hampir mendekati nilai observasi apabila dibandingkan dengan hasil dugaan NWP. Hasil dugaan NWP masih memiliki bias yang cukup besar. Gambar 4.2 menunjukkan plot model SIMPLS dan model NWP yang hampir mendekati nilai observasi, sedangkan Gambar 4.1 dan 4.3 menunjukkan bahwa plot hasil dugaan NWP dapat dikatakan jauh dari nilai observasi. Oleh karena itu, nilai RMSEP untuk prediksi T_{\max} dan RH berkriteria sedang - baik.

4.3 Perbandingan Akurasi Prakiraan MOS dengan NWP

Berdasarkan perbandingan antara data observasi, hasil dugaan SIMPLS, dan hasil dugaan NWP yang telah disajikan pada subbab sebelumnya, dapat dilihat bahwa NWP masih memiliki bias yang cukup besar. Besarnya bias tersebut dapat dikoreksi oleh SIMPLS yang dihitung menggunakan %IM. Hasil dugaan NWP untuk variabel T_{\max} , T_{\min} , dan RH didapatkan dari data NWP pada grid 5, dikarenakan grid tersebut merupakan grid yang paling dekat

dari stasiun pengamatan. Besarnya bias pada NWP yang terkoreksi oleh SIMPLS di tiga stasiun disajikan pada Tabel 4.16.

Tabel 4.16 Nilai %IM

Stasiun	Variabel	RMSEP _{SIMPLS}	RMSEP _{NWP}	%IM
Juanda	T _{max}	0,8919	11,0382	91,92
	T _{min}	0,7790	1,4656	46,85
	RH	4,1944	13,7023	69,39
Soekarno Hatta	T _{max}	1,0510	10,1960	89,69
	T _{min}	0,8606	1,1647	26,10
	RH	3,4195	7,2300	52,70
Ngurah Rai	T _{max}	1,1142	1,6613	32,93
	T _{min}	1,4771	5,0451	70,72
	RH	4,2615	7,2186	40,96

Nilai RMSEP yang dihasilkan oleh NWP lebih besar apabila dibandingkan dengan RMSEP SIMPLS. Model SIMPLS untuk unsur cuaca T_{max} dapat mengoreksi bias NWP sebesar 32,93 – 91,92 persen; 26,10 – 70,72 persen untuk T_{min}; dan 40,96 – 69,39 persen untuk RH.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Mengacu pada tujuan penelitian serta hasil analisis dan pembahasan, maka diperoleh kesimpulan sebagai berikut.

1. Model SIMPLS yang terbentuk pada Stasiun Juanda adalah sebagai berikut.

$$\begin{aligned}\hat{y}_{T_{\max(t)}} = & -0,0496 \text{ IC.dew}_{(t-1)} + 0,0042 \text{ IC.hicloud}_{(t-1)} + 0,1340 \\ & \text{IC1.totrain}_{(t-1)} - 0,0154 \text{ IC2.totrain}_{(t-1)} + 0,0692 \\ & \text{IC1.lowcloud}_{(t-1)} - 0,0253 \text{ IC2.lowcloud}_{(t-1)} - 0,0196 \\ & \text{IC.midcloud}_{(t-1)} + 0,0437 \text{ IC.mslp}_{(t-1)} + 0,0519 \text{ IC.rhum}_{(t-1)} \\ & - 0,0837 \text{ IC.shum}_{(t-1)} - 0,1052 \text{ IC.surpres}_{(t-1)} + 0,1296 \\ & \text{IC1.survis}_{(t-1)} - 0,0532 \text{ IC2.survis}_{(t-1)} - 0,2149 \text{ IC1.temp}_{(t-1)} \\ & - 0,1089 \text{ IC2.temp}_{(t-1)} + 0,0207 \text{ IC.totcloud}_{(t-1)} - 0,2071 \\ & \text{IC.uwind}_{(t-1)} - 0,0974 \text{ IC1.vwind}_{(t-1)} - 0,1286 \text{ IC2.vwind}_{(t-1)} \\ & - 0,0029 \text{ IC.windgust}_{(t-1)}\end{aligned}$$

$$\begin{aligned}\hat{y}_{T_{\min(t)}} = & -0,1639 \text{ IC.dew}_{(t-1)} - 0,0089 \text{ IC.hicloud}_{(t-1)} + 0,1493 \\ & \text{IC1.totrain}_{(t-1)} - 0,1400 \text{ IC2.totrain}_{(t-1)} + 0,0213 \\ & \text{IC1.lowcloud}_{(t-1)} - 0,0149 \text{ IC2.lowcloud}_{(t-1)} - 0,0056 \\ & \text{IC.midcloud}_{(t-1)} + 0,0569 \text{ IC.mslp}_{(t-1)} + 0,0418 \text{ IC.rhum}_{(t-1)} \\ & - 0,1478 \text{ IC.shum}_{(t-1)} - 0,0708 \text{ IC.surpres}_{(t-1)} + 0,1014 \\ & \text{IC1.survis}_{(t-1)} - 0,0770 \text{ IC2.survis}_{(t-1)} - 0,0769 \text{ IC1.temp}_{(t-1)} \\ & - 0,0850 \text{ IC2.temp}_{(t-1)} - 0,0011 \text{ IC.totcloud}_{(t-1)} + 0,0618 \\ & \text{IC.uwind}_{(t-1)} + 0,0356 \text{ IC1.vwind}_{(t-1)} + 0,0330 \text{ IC2.vwind}_{(t-1)} \\ & - 0,0839 \text{ IC.windgust}_{(t-1)}\end{aligned}$$

$$\begin{aligned}\hat{y}_{RH(t)} = & -0,0536 \text{ IC.dew}_{(t-1)} + 0,0330 \text{ IC.hicloud}_{(t-1)} - 0,1068 \\ & \text{IC1.totrain}_{(t-1)} - 0,0296 \text{ IC2.totrain}_{(t-1)} - 0,0161 \\ & \text{IC1.lowcloud}_{(t-1)} + 0,0209 \text{ IC2.lowcloud}_{(t-1)} - 0,0746 \\ & \text{IC.midcloud}_{(t-1)} - 0,0230 \text{ IC.mslp}_{(t-1)} + 0,0111 \text{ IC.rhum}_{(t-1)} \\ & - 0,0198 \text{ IC.shum}_{(t-1)} + 0,0660 \text{ IC.surpres}_{(t-1)} - 0,1055 \\ & \text{IC1.survis}_{(t-1)} + 0,0018 \text{ IC2.survis}_{(t-1)} + 0,0889 \text{ IC1.temp}_{(t-1)} \\ & - 0,0328 \text{ IC2.temp}_{(t-1)} - 0,0365 \text{ IC.totcloud}_{(t-1)} + 0,1279 \\ & \text{IC.uwind}_{(t-1)} + 0,1640 \text{ IC1.vwind}_{(t-1)} + 0,2325 \text{ IC2.vwind}_{(t-1)} \\ & + 0,0552 \text{ IC.windgust}_{(t-1)}\end{aligned}$$

2. Akurasi prakiraan cuaca yang dihasilkan oleh SIMPLS menunjukkan bahwa RMSEP untuk T_{\max} di stasiun Juanda berkriteria baik, sedangkan di Stasiun Soekarno Hatta dan Ngurah Rai berkriteria sedang. RMSEP untuk T_{\min} berkriteria baik di Stasiun Juanda dan Soekarno Hatta. Namun, RMSEP T_{\min} di Stasiun Ngurah Rai berkriteria buruk. Nilai RMSEP RH di tiga stasiun berkriteria baik.
3. Model SIMPLS dapat mengoreksi bias model NWP dikarenakan RMSEP SIMPLS yang lebih rendah dibandingkan RMSEP NWP untuk semua unsur cuaca di tiga stasiun. Secara umum, nilai %IM untuk prediksi T_{\max} , T_{\min} , dan RH berkisar antara 26 – 92 persen.

5.2 Saran

Pemodelan hasil penelitian ini disarankan untuk digunakan oleh BMKG untuk memprediksi cuaca jangka pendek karena menghasilkan RMSEP yang lebih kecil dibandingkan pemodelan NWP. Namun, akurasi prakiraan yang ditunjukkan dengan nilai RMSEP di salah satu stasiun masih belum memenuhi ekspektasi. Hal tersebut dapat dikarenakan terdapat banyaknya data yang *missing*. Disarankan untuk penelitian berikutnya agar menggunakan periode data *training* yang tidak mengandung *missing value* agar dapat meng-*capture* pola musiman, sehingga diperoleh model yang terbaik.

DAFTAR PUSTAKA

- [BNPB] Badan Nasional Penanggulangan Bencana. (2016). 95 *Persen Bencana di Indonesia Disebabkan Hidrometeorologi*. Diakses dari <http://surabaya.tribunnews.com/2016/06/19/bnpb-95-persen-bencana-di-indonesia-disebabkan-hidrometeorologi> pada 12 Januari 2017.
- [BMKG] Badan Meteorologi, Klimatologi, dan Geofisika. (2004). *Verifikasi dan Jangkauan Prakiraan Cuaca Jangka Pendek*. Jakarta: BMKG.
- [BMKG] Badan Meteorologi, Klimatologi, dan Geofisika. (2014). *Kajian Kinerja Peralatan Klimatologi dan Kualitas Udara*. Jakarta: BMKG.
- Al-Yahyai, S., Charabi, Y., & Gastli, A. (2010). Review of the Use of Numerical Weather Prediction (NWP) Models for Wind Energy Assessment. *Renewable and Sustainable Energy Reviews*, 3192-3198.
- Anuravega, A. (2013). *Post Processing Peramalan Unsur Cuaca dengan Model Output Statistics (MOS) : Studi Perbandingan Antara Reduksi Dimensi Independent Component Analysis (ICA) dan Principal Component Analysis*. Surabaya: Tugas Akhir, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.
- Boulesteix, Laure, A., & Strimmer, K. (2006). Partial Least Square : A Versatile Tool for the Analysis of High-Dimensional Genomic Data. *Journal of Briefings in Bioinformatics*, 32-44.
- Davis, J. (2004). Bias Removal and Model Consensus Forecast of Maximum and Minimum Temperatures using The Graphical Forecast Editor. *NOOA NWS Office Tusco*, 10-13.

- De Jong, S. (1993). SIMPLS: An Alternative Approach to Partial Least Squares Regression. *Original Research Paper Chemometrics and Intelligent Laboratory System*, 18, 251-263.
- Geladi, H., & Kowalski, B. R. (1986). Partial Least Squares Regression : A Tutorial. *Analytical Chimica Acta* 185, 1-17.
- Glahn, H., & Lowry, D. (1972). The Use Model Output Statistics (MOS) in Objective Weather Forecasting. *Journal of Application Meteorologi*, 1203-1211.
- Haykin, S. (2009). Independent Component Analysis, A New Concept?. *Signal Processing*, 36, 287-314.
- Hyvärinen, A., & Oja, E. (2000). *Independent Component Analysis : Algorithms and Applications*. Finland: Helsinki University of Technology.
- Idayati. (2014). *Reduksi Dimensi NWP dengan Transformasi Wavelet Diskrit (TWD) dan Principal Componetn Analysis (PCA) untuk Pra-pemrosesan Data dalam Pemodelan Prakiraan Curah Hujan Jangka Pendek* . Surabaya: Tugas Akhir, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.
- Idowu, O., & Rautenbach, C. (2008). *Model Output Statstics to Improve Severe Storms Prediction Over Western Sahel*. Pretoria: University of Pretoria.
- Langlois, D., Chartier, S., & Gosselin, D. (2010). *An Introduction to Independent Component Analysis : InfoMAx and FastICA Algorithms*. Ottawa: University of Ottawa.
- Li, L. (2006). Partial Least Squares Modelling to Quantify Lunar Soil Composition With Hyperspectral Reflectance Measurements. *Journal of Geophysical Research*, 111, E04002.

- Linacre, E., & Geerts, B. (2003). *Climate and Weather Explained*. New York: Routledge.
- Neille, P., & Hanson, K. (2004). *Are Model Output Statistics Still Needed?* Seattle: Weather Services International, Inc.
- [PAKLIM] Policy Advice for Environment and Climate Change. (2016). Diakses dari <http://paklim.org/index.php/about/climate-change-in-indonesia.html> pada 14 Januari 2016.
- Raible, C.C., Bischof, G., & Fraedrich, K. (1998). *Statistical Single-Station Short-Term Forecasting of Temperature and Probability of Precipitation: Area Interpolation and NWP Combination*. Jerman: Hamburg University.
- Ristanti, D. (2009). *Inter-Relasi Keluaran Model NWP Untuk Potensi Prakiraan Cuaca Jangka Pendek Tiga Wilayah Tipe Hujan di Indonesia*. Bogor: Departemen Geofisika dan Meteorologi, Institut Pertanian Bogor.
- Rozumalski, R. (2010). *A Nearly Complete Guide to The WRF EMS V3*. Boulder: NOAA/NWS National SOO Science and Training Resource Coordinator Forcaser Decision Training Branch.
- Safitri, R. (2012). *Model Output Statistics dengan Projection Pursuit Regression untuk Meramalkan Suhu Minimum, Suhu Maksimum, dan Kelembapan*. Surabaya: Tugas Akhir, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.
- Sari, I. (2013). *Pendekatan Regresi Partial Least Square Univariate dan Multivariate Response untuk Memprediksi Suhu dan Kelembapan*. Surabaya: Tesis, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.
- Septiana, L. (2014). *Statistically Inspired Modification of Partial Least Square untuk Memprediksi Suhu dan Kelembapan dengan Pra-pemrosesan Principal Component Analysis*.

- Surabaya: Tugas Akhir, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.
- Setiarnoputera, M. (2015). *Prakiraan Suhu dan Kelembapan di DKI Jakarta Menggunakan Multivariate Partial Least Square (M-PLS)*. Surabaya: Tugas Akhir, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.
- Soebagijo, T. (2011). *Pengembangan Structural Equation Modeling (SEM) dengan Partial Least Square (PLS)*. Surabaya: Tesis, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.
- Utoyo, B. (2009). *Geografi Membuka Cakrawala Dunia*. Pusat Perbukuan Departemen Pendidikan Nasional.
- Wigena, A., & Alamudi, A. (1997). *Algoritma Metode Kuadrat Terkecil Parsial untuk Kalibrasi Peubah Ganda*. Bogor: Lembaga Penelitian dan Pemberdayaan Masyarakat.
- Wijayanto, I., Hidayat, B., & Suyanto. (2011). *Pemisahan Suara Musik Instrumental Menggunakan Metode Independent Component Analysis dan Pemodelan Autoregressive Moving Average*. Bandung: Institut Teknologi Telkom Bandung.
- Wilks, D. (2006). *Statistical Methods in the Atmospheric Sciences (2nd)*. Boston: Elviesier.
- Wulandari, S. P. (2000). *Analisis Hubungan Antara Variabel Ekonomi dengan Kesejahteraan Menggunakan Metode PLS (Partial Least Squares)*. Tesis, Jurusan Statistika, Institut Pertanian Bogor.

LAMPIRAN

Lampiran 1. Data NWP Stasiun Juanda Variabel *Dew2m*

Grid 1	Grid 2	Grid 3	...	Grid 7	Grid 8	Grid 9
21,3514	21,0653	21,3534	...	23,0969	23,2412	24,4526
21,4975	21,1422	21,5663	...	23,0774	23,2573	24,4143
20,7797	19,9056	20,4137	...	23,2297	23,3417	24,3022
20,1599	19,1608	19,2612	...	22,0095	22,0233	23,4213
19,7116	18,5630	18,2807	...	20,9955	21,2238	23,0765
20,0039	19,2318	19,2444	...	22,5089	22,6725	23,9211
19,6311	19,3232	19,3319	...	21,2004	21,5135	23,5217
20,4168	20,4028	20,6668	...	21,1294	21,4325	23,3486
19,9692	19,7744	20,5004	...	22,4591	22,7612	24,3307
21,2303	21,3301	22,0544	...	23,2069	23,4530	24,3738
21,4576	21,4419	22,1810	...	23,2752	23,4338	24,2200
21,3468	21,1952	21,8427	...	22,9032	23,0278	23,9594
21,5987	21,3521	22,0131	...	23,5930	23,6959	24,3933
20,4716	20,5121	21,3200	...	22,8944	23,1955	24,2257
20,0810	20,1187	20,7835	...	22,4833	22,6108	23,6594
21,0077	20,8517	21,3801	...	22,7147	22,7467	23,9270
20,7549	20,6312	21,1077	...	22,7090	22,7529	23,9632
20,8998	20,7458	21,2393	...	23,0984	23,1169	24,0998
⋮	⋮	⋮	⋮	⋮	⋮	⋮
21,1109	21,1711	21,8256	...	22,9768	23,1263	24,2804
19,4551	19,8903	20,8504	...	21,9293	22,4684	24,4639
20,9791	20,9217	21,5240	...	21,9512	22,4887	24,3017
20,0371	20,3577	21,2899	...	21,6574	22,1396	24,1618
19,7592	19,8539	20,6911	...	21,9957	22,6315	24,5928
21,0468	21,0906	21,7456	...	22,3313	22,6949	23,9678
21,1041	21,2482	21,8385	...	22,5501	23,0646	24,1652

Lampiran 2. Data Observasi Stasiun Juanda

T_{max}	T_{min}	RH
30,10	24,80	82,61
32,60	24,30	83,97
32,40	24,20	84,76
32,70	24,50	75,68
33,70	24,70	73,77
33,40	25,20	71,73
32,90	24,80	68,91
34,00	24,40	68,27
32,90	25,20	73,04
33,00	26,10	79,28
32,50	24,90	89,83
32,50	24,50	79,40
31,60	25,20	75,93
32,50	24,90	84,07
32,60	24,80	81,51
32,10	25,00	86,96
30,80	23,60	86,67
⋮	⋮	⋮
33,00	21,00	82,57
33,20	24,70	77,62
34,00	26,00	74,03
33,80	26,00	76,86
33,40	26,80	78,03
31,80	25,60	81,80
32,00	26,40	84,91
31,40	25,80	76,99

Lampiran 3. Data NWP Stasiun Soekarno Hatta Variabel
Dew2m

Grid 1	Grid 2	Grid 3	...	Grid 7	Grid 8	Grid 9
21,9426	21,8240	21,6360	...	24,2015	24,2307	24,2862
21,6891	21,5438	21,4623	...	23,9993	23,9980	24,0708
22,0221	21,7568	21,5360	...	23,8554	23,8936	24,0019
21,9723	21,7881	21,7359	...	23,7704	23,7506	23,7799
21,9934	21,7926	21,6909	...	24,0614	24,0150	24,0278
21,6942	21,4726	21,3647	...	23,8984	23,9046	24,0203
21,8910	21,6747	21,5493	...	24,1483	24,1179	24,2025
21,8113	21,6461	21,4573	...	24,3303	24,3144	24,4638
21,0110	20,6666	20,3886	...	23,9753	23,9045	23,9708
21,6518	21,3638	21,3173	...	23,7606	23,8607	24,0481
22,0415	22,0128	22,0905	...	24,1349	24,2989	24,4587
21,6360	21,7065	21,9044	...	24,2609	24,3275	24,3601
21,8451	22,0376	22,2149	...	24,1428	24,2557	24,3454
22,8913	23,2296	23,1831	...	24,2143	24,2925	24,3797
21,4336	21,8564	22,1733	...	24,2276	24,2595	24,3638
21,7660	22,2144	22,5750	...	24,4284	24,4842	24,5496
21,6906	22,0495	22,3513	...	24,4273	24,4771	24,4948
21,9344	22,2368	22,2574	...	24,0033	24,0388	24,1431
⋮	⋮	⋮	⋮	⋮	⋮	⋮
22,5171	22,7842	22,7597	...	24,1991	24,1849	24,1905
23,0286	23,0029	22,9444	...	24,3253	24,3122	24,2943
22,6597	22,7195	22,7171	...	24,1316	24,1912	24,2459
23,0846	23,2276	23,1772	...	24,2131	24,3134	24,3852
21,7929	22,2257	22,4267	...	24,0190	24,0866	24,0162
21,8622	21,8633	21,8239	...	24,2086	24,2873	24,3589
22,3494	22,3449	22,1051	...	24,3533	24,3004	24,2807

Lampiran 4. Data Observasi Stasiun Soekarno Hatta

T_{max}	T_{min}	RH
29.90	23.40	86.12
28.40	24.20	88.10
31.60	23.80	80.94
31.60	24.40	79.33
32.20	24.00	78.46
31.20	24.20	80.33
32.60	25.40	76.13
32.20	24.20	77.31
31.80	24.00	77.28
32.50	25.00	96.02
28.60	23.80	87.75
30.20	24.20	86.77
31.60	23.40	82.40
32.50	24.20	91.47
30.00	23.00	84.42
30.20	24.20	78.91
26.40	24.60	94.13
⋮	⋮	⋮
32.60	23.50	76.37
31.80	23.70	81.48
32.90	24.10	76.93
33.00	24.70	79.96
31.00	24.80	82.61
32.80	23.40	80.57
33.20	24.50	78.24
34.60	26.20	72.71

Lampiran 5. Data NWP Stasiun Ngurah Rai Variabel *Dew2m*

Grid 1	Grid 2	Grid 3	...	Grid 7	Grid 8	Grid 9
24,8273	24,8378	24,8127	...	23,7800	22,2502	21,9304
24,8347	24,8628	24,9075	...	24,1130	22,5541	22,2210
25,2812	25,3011	25,3341	...	24,5782	23,0816	22,6323
24,3507	24,3697	24,4262	...	24,1807	22,4906	21,9870
24,7611	24,8408	24,9178	...	23,8065	22,0427	21,6310
25,4567	25,5121	25,5368	...	22,9804	20,7960	20,3627
25,4745	25,4480	25,4017	...	23,5778	21,4116	20,9077
26,2610	26,1815	26,1001	...	24,5727	22,8345	22,3797
25,1085	25,0866	25,0647	...	23,6517	21,8750	21,4885
24,4581	24,3957	24,3271	...	23,0466	21,1700	20,5375
24,1198	24,1536	24,1947	...	23,2689	21,8482	21,7691
23,8480	23,8526	23,8558	...	23,3186	22,3788	22,3103
24,0931	24,0226	23,9011	...	23,4246	22,2079	22,1604
23,2442	23,3733	23,5468	...	23,0253	21,5710	21,5678
23,5231	23,4447	23,3761	...	22,8766	21,3430	21,2603
23,7704	23,7847	23,8037	...	23,1801	21,7971	21,8756
24,0393	24,0219	24,0333	...	23,4821	22,7275	22,7945
24,0500	24,0645	24,0666	...	23,4746	22,4260	22,4846
⋮	⋮	⋮	⋮	⋮	⋮	⋮
24,9007	24,9749	25,0345	...	24,1288	22,6064	22,7100
25,1158	25,1782	25,2562	...	24,1424	22,6925	22,7526
25,8543	25,9549	26,0063	...	25,1860	23,8100	23,7686
25,0684	25,0871	25,1017	...	23,9483	22,5319	22,5813
25,7340	25,7827	25,7930	...	24,6508	23,1766	23,1554
24,8964	24,9227	24,9487	...	24,4176	23,1045	23,2997
24,1363	24,1382	24,1452	...	23,4808	22,3464	22,3594

Lampiran 6. Data Observasi Stasiun Ngurah Rai

T_{max}	T_{min}	RH
29,80	24,80	77,48
30,80	24,20	76,20
31,00	26,60	74,91
30,20	24,80	77,41
30,50	24,70	77,53
30,90	27,10	74,17
31,70	23,00	75,82
30,90	25,90	74,95
31,20	27,80	76,92
30,40	23,60	83,07
30,30	23,40	82,98
30,60	24,60	84,78
32,50	21,80	81,78
30,60	24,20	77,01
30,60	24,80	78,52
29,60	25,30	80,66
30,30	25,80	82,88
⋮	⋮	⋮
31,60	24,60	85,59
31,70	24,00	80,43
31,90	25,20	80,73
32,20	25,90	79,73
32,40	26,10	81,18
30,50	23,40	83,43
30,40	24,20	90,17
29,40	27,00	87,59

**Lampiran 7. Rata-rata dan Standar Deviasi Variabel NWP
Stasiun Juanda**

Variabel (grid)	Rata- Rata	Standar Deviasi	Variabel (grid)	Rata-Rata	Standar Deviasi
<i>Dew</i> (1)	19,2249	2,1929	<i>Surpres</i> (1)	954,2472	1,2751
<i>Dew</i> (2)	19,5323	1,9402	<i>Surpres</i> (2)	959,2134	1,3415
<i>Dew</i> (3)	20,5129	1,6860	<i>Surpres</i> (3)	979,1820	1,4179
<i>Dew</i> (4)	20,4982	2,2151	<i>Surpres</i> (4)	998,4280	1,4427
<i>Dew</i> (5)	21,1345	1,8654	<i>Surpres</i> (5)	1004,4138	1,4849
<i>Dew</i> (6)	23,5134	0,9242	<i>Surpres</i> (6)	1009,9857	1,5147
<i>Dew</i> (7)	21,2659	2,0276	<i>Surpres</i> (7)	1009,1644	1,4772
<i>Dew</i> (8)	21,8737	1,6902	<i>Surpres</i> (8)	1009,4780	1,4848
<i>Dew</i> (9)	23,7208	0,8823	<i>Surpres</i> (9)	1008,4542	1,4939
⋮	⋮	⋮	⋮	⋮	⋮
<i>Shum</i> (1)	0,0148	0,0019	<i>Wndgust</i> (1)	4,9437	1,5525
<i>Shum</i> (2)	0,0150	0,0017	<i>Wndgust</i> (2)	5,6732	1,7592
<i>Shum</i> (3)	0,0156	0,0016	<i>Wndgust</i> (3)	6,2796	1,9971
<i>Shum</i> (4)	0,0153	0,0020	<i>Wndgust</i> (4)	4,5539	1,4342
<i>Shum</i> (5)	0,0158	0,0017	<i>Wndgust</i> (5)	5,1794	1,6206
<i>Shum</i> (6)	0,0181	0,0010	<i>Wndgust</i> (6)	6,3269	2,0342
<i>Shum</i> (7)	0,0159	0,0019	<i>Wndgust</i> (7)	4,5706	1,4665
<i>Shum</i> (8)	0,0164	0,0016	<i>Wndgust</i> (8)	5,3420	1,7066
<i>Shum</i> (9)	0,0183	0,0010	<i>Wndgust</i> (9)	6,2049	1,9791

Lampiran 8. Rata-rata dan Standar Deviasi Variabel NWP
Stasiun Soekarno Hatta

Variabel (grid)	Rata- Rata	Standar Deviasi	Variabel (grid)	Rata-Rata	Standar Deviasi
<i>Dew</i> (1)	20,9202	1,8248	<i>Surpres</i> (1)	997,8808	1,3184
<i>Dew</i> (2)	21,0253	1,9350	<i>Surpres</i> (2)	1002,3235	1,3242
<i>Dew</i> (3)	21,0310	1,9680	<i>Surpres</i> (3)	1003,7105	1,3216
<i>Dew</i> (4)	21,7079	1,5153	<i>Surpres</i> (4)	1006,9623	1,3644
<i>Dew</i> (5)	22,0002	1,5081	<i>Surpres</i> (5)	1008,7741	1,3639
<i>Dew</i> (6)	23,3843	0,9797	<i>Surpres</i> (6)	1009,5398	1,3599
<i>Dew</i> (7)	23,7752	0,7452	<i>Surpres</i> (7)	1009,5402	1,3804
<i>Dew</i> (8)	23,8175	0,7403	<i>Surpres</i> (8)	1009,8269	1,3764
<i>Dew</i> (9)	23,8419	0,7532	<i>Surpres</i> (9)	1009,8251	1,3736
⋮	⋮	⋮	⋮	⋮	⋮
<i>Shum</i> (1)	0,0157	0,0017	<i>Wndgust</i> (1)	4,2988	1,4758
<i>Shum</i> (2)	0,0157	0,0018	<i>Wndgust</i> (2)	4,3954	1,3789
<i>Shum</i> (3)	0,0157	0,0018	<i>Wndgust</i> (3)	4,4772	1,3485
<i>Shum</i> (4)	0,0163	0,0015	<i>Wndgust</i> (4)	4,2411	1,4238
<i>Shum</i> (5)	0,0165	0,0015	<i>Wndgust</i> (5)	4,3196	1,3852
<i>Shum</i> (6)	0,0179	0,0010	<i>Wndgust</i> (6)	4,7856	1,4372
<i>Shum</i> (7)	0,0184	0,0008	<i>Wndgust</i> (7)	4,7857	1,5089
<i>Shum</i> (8)	0,0184	0,0008	<i>Wndgust</i> (8)	4,8764	1,5797
<i>Shum</i> (9)	0,0184	0,0008	<i>Wndgust</i> (9)	5,1125	1,6792

Lampiran 9. Rata-rata dan Standar Deviasi Variabel NWP
Stasiun Ngurah Rai

Variabel (grid)	Rata- Rata	Standar Deviasi	Variabel (grid)	Rata- Rata	Standar Deviasi
<i>Dew</i> (1)	24,2424	0,8603	<i>Surpres</i> (1)	1010,5145	1,6859
<i>Dew</i> (2)	24,2367	0,8584	<i>Surpres</i> (2)	1010,4485	1,6818
<i>Dew</i> (3)	24,2256	0,8594	<i>Surpres</i> (3)	1010,4992	1,6784
<i>Dew</i> (4)	24,1798	0,8221	<i>Surpres</i> (4)	1010,3613	1,6586
<i>Dew</i> (5)	24,0771	0,8325	<i>Surpres</i> (5)	1009,6594	1,6564
<i>Dew</i> (6)	24,0521	0,8335	<i>Surpres</i> (6)	1009,2569	1,6481
<i>Dew</i> (7)	23,3460	0,8496	<i>Surpres</i> (7)	991,9240	1,5244
<i>Dew</i> (8)	21,7285	1,0989	<i>Surpres</i> (8)	977,8849	1,4786
<i>Dew</i> (9)	21,8241	1,0613	<i>Surpres</i> (9)	977,3327	1,5177
⋮	⋮	⋮	⋮	⋮	⋮
<i>Shum</i> (1)	0.0189	0.0010	<i>Wndgust</i> (1)	6,3123	2,0991
<i>Shum</i> (2)	0.0189	0.0010	<i>Wndgust</i> (2)	6,2999	2,0975
<i>Shum</i> (3)	0.0188	0.0010	<i>Wndgust</i> (3)	6,2859	2,1047
<i>Shum</i> (4)	0.0188	0.0009	<i>Wndgust</i> (4)	6,2709	2,1102
<i>Shum</i> (5)	0.0187	0.0009	<i>Wndgust</i> (5)	6,1676	2,0198
<i>Shum</i> (6)	0.0187	0.0009	<i>Wndgust</i> (6)	6,0169	1,9341
<i>Shum</i> (7)	0.0182	0.0009	<i>Wndgust</i> (7)	5,9959	1,9966
<i>Shum</i> (8)	0.0168	0.0011	<i>Wndgust</i> (8)	5,2852	1,6716
<i>Shum</i> (9)	0.0169	0.0011	<i>Wndgust</i> (9)	5,0061	1,5760

Lampiran 10. Jumlah Komponen Independen Variabel NWP
Pada Stasiun Soekarno Hatta

No.	Variabel	Jumlah IC	Nilai Eigen	Varians Kumulatif (%)
1.	<i>Dew Point</i>	1	8,4700	94,15
2.	<i>High Cloud</i>	1	8,1661	90,74
3.	<i>Total Rainfall</i>	2	6,4883; 1,4141	87,80
4.	<i>Low Cloud</i>	2	5,3986; 1,6873	78,83
5.	<i>Middle Cloud</i>	1	8,2803	92,00
6.	<i>Mean Sea Level Pressure</i>	1	8,9352	99,28
7.	<i>Relative Humidity</i>	2	7,6125 ; 1,1988	97,90
8.	<i>Specific Humidity</i>	1	8,3438	92,71
9.	<i>Surface Pressure</i>	1	8,9671	99,63
10.	<i>Surface</i>	2	6,5861; 1,2482	87,05
11.	<i>Temperature</i>	2	5,6133; 3,0473	96,23
12.	<i>Total Cloud</i>	1	8,2431	91,59
13.	<i>U Wind</i>	1	8,8017	97,80
14.	<i>V Wind</i>	1	7,9840	88,71
15.	<i>Windgust</i>	1	8,2935	92,15

Lampiran 11. Jumlah Komponen Independen Variabel NWP
Pada Stasiun Ngurah Rai

No.	Variabel	Jumlah IC	Nilai Eigen	Varsians Kumulatif (%)
1.	<i>Dew Point</i>	1	8,4528	93,92
2.	<i>High Cloud</i>	1	8,1282	90,31
3.	<i>Total Rainfall</i>	1	7,7412	86,01
4.	<i>Low Cloud</i>	2	7,0784 ; 1,0341	90,14
5.	<i>Middle Cloud</i>	1	8,4184	93,54
6.	<i>Mean Sea Level Pressure</i>	1	8,9249	99,17
7.	<i>Relative Humidity</i>	2	6,9772 ; 1,7732	97,23
8.	<i>Specific Humidity</i>	1	8,4939	94,38
9.	<i>Surface Pressure</i>	1	8,9657	99,62
10.	<i>Survis</i>	2	4,6088 ; 2,1934	75,58
11.	<i>Temperature</i>	2	7,2383 ; 1,7033	99,35
12.	<i>Total Cloud</i>	1	8,4310	93,68
13.	<i>U Wind</i>	1	8,9434	99,37
14.	<i>V Wind</i>	1	8,7253	96,95
15.	<i>Windgust</i>	1	8,6552	96,17

Lampiran 12. Nilai Press yang Terbentuk Pada Stasiun Soekarno
Hatta

Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
1.	1,291	11.	1,205
2.	1,218	12.	1,206
3.	1,203	13.	1,211
4.	1,202	14.	1,213
5.	1,206	15.	1,209
6.	1,207	16.	1,207
7.	1,217	17.	1,211
8.	1,217	18.	1,213
9.	1,212	19.	1,226
10.	1,213	20.	1,230

Lampiran 13. Nilai Press yang Terbentuk Pada Stasiun Ngurah
Rai

Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
1.	1,425	11.	1,301
2.	1,306	12.	1,308
3.	1,303	13.	1,310
4.	1,305	14.	1,308
5.	1,301	15.	1,307
6.	1,298	16.	1,307
7.	1,300	17.	1,304
8.	1,299	18.	1,307
9.	1,301	19.	1,309
10.	1,304		

Lampiran 14. Nilai Pembobot X untuk Pemodelan SIMPLS di Stasiun Soekarno Hatta

No.	Variabel	w ₁	w ₂	w ₃	w ₄
1.	IC.dew	0,0036	0,0041	0,0032	-0,0071
2.	IC.hicloud	0,0013	-0,0027	-0,0035	-0,0002
3.	IC1.totrain	0,0020	-0,0026	-0,0021	-0,0014
4.	IC2.totrain	-0,0001	0,0011	-0,0005	-0,0031
5.	IC1.lowcloud	0,0005	-0,0003	-0,0034	0,0019
6.	IC2.midcloud	0,0001	-0,0011	-0,0002	-0,0003
7.	IC.mslp	0,0018	-0,0020	-0,0044	-0,0032
8.	IC1.rhum	0,0017	0,0049	-0,0015	0,0075
9.	IC2.rhum	0,0038	-0,0014	0,0044	-0,0009
10.	IC.shum	0,0002	-0,0003	0,0002	0,0039
11.	IC.surpres	0,0036	0,0041	0,0031	-0,0067
12.	IC1.survis	-0,0019	-0,0047	0,0018	-0,0070
13.	IC2.survis	-0,0005	0,0002	0,0053	0,0024
14.	IC3.survis	0,0000	0,0010	0,0001	-0,0015
15.	IC1.temp	0,0015	0,0004	0,0002	0,0043
16.	IC2.temp	-0,0007	0,0064	-0,0035	-0,0086
17.	IC.totcloud	0,0019	-0,0027	-0,0049	-0,0017
18.	IC.uwind	0,0028	-0,0075	0,0043	0,0082
19.	IC.vwind	-0,0015	0,0060	-0,0060	-0,0043
20.	IC.windgust	0,0001	0,0000	0,0005	-0,0054

Lampiran 15. Nilai Pembobot X untuk Pemodelan SIMPLS di Stasiun Ngurah Rai

No.	Variabel	w ₁	w ₂	...	w ₅	w ₆
1.	IC.dew	-0,0043	-0,0047	...	-0,0032	0,0038
2.	IC.hicloud	-0,0008	0,0027	...	-0,0073	-0,0055
3.	IC.totrain	-0,0008	0,0042	...	0,0057	-0,0082
4.	IC1.lowcloud	0,0013	-0,0001	...	-0,0079	-0,0038
5.	IC2.lowcloud	0,0002	0,0004	...	0,0025	0,0019
6.	IC.midcloud	0,0006	-0,0043	...	0,0012	-0,0040
7.	IC.mslp	0,0024	-0,0012	...	-0,0055	0,0050
8.	IC1.rhum	0,0002	-0,0007	...	0,0069	-0,0004
9.	IC2.rhum	0,0007	-0,0009	...	-0,0059	-0,0049
10.	IC.shum	-0,0043	-0,0047	...	-0,0034	0,0033
11.	IC.surpres	-0,0024	0,0016	...	0,0071	-0,0099
12.	IC1.survis	-0,0002	-0,0015	...	0,0043	-0,0116
13.	IC2.survis	0,0001	-0,0004	...	-0,0005	-0,0030
14.	IC1.temp	-0,0033	-0,0028	...	-0,0078	0,0009
15.	IC2.temp	0,0008	0,0026	...	0,0055	0,0150
16.	IC.totcloud	-0,0006	0,0038	...	-0,0066	-0,0023
17.	IC.uwind	-0,0014	0,0025	...	0,0021	0,0150
18.	IC.vwind	0,0025	-0,0007	...	-0,0033	-0,0049
19.	IC.windgust	0,0026	0,0014	...	0,0007	0,0101

Lampiran 16. Nilai *X-scores* di Stasiun Soekarno Hatta

n	t₁	t₂	t₃	t₄
1.	-0,0515	0,0259	-0,0351	-0.0429
2.	-0,0741	0,0564	0,0556	0.0014
3.	-0,0652	0,0098	0,0491	-0.0390
4.	-0,0672	-0,0192	0,0769	-0.0887
5.	-0,0340	-0,0680	-0,0184	-0.0988
6.	-0,0272	-0,0343	-0,0025	-0.0616
7.	-0,0421	-0,0025	0,0001	-0.0173
8.	-0,0229	-0,0100	-0,0417	-0.0125
9.	-0,0094	-0,0051	-0,0440	-0.0727
10.	-0,0144	-0,0078	-0,0631	-0.0709
11.	-0,0598	0,0143	-0,0422	-0.0853
12.	-0,0701	0,0747	0,0196	-0.0088
13.	-0,0341	0,0197	-0,0527	-0.0131
14.	-0,1113	0,0862	0,0622	0.0438
15.	-0,0348	0,0097	-0,0256	-0.0393
⋮	⋮	⋮	⋮	⋮
338.	-0,0425	-0,0409	0,0338	-0,0148
339.	-0,0478	-0,0088	0,0611	-0,0884
340.	-0,0913	-0,0163	0,2472	0,0774
341.	-0,0201	-0,0594	0,0204	-0,0108
342.	-0,0082	-0,0997	0,0372	-0,0238
343.	0,0006	-0,0450	0,0320	0,0544
344.	-0,0292	-0,0497	0,0891	0,0839
345.	-0,0645	0,0069	0,0040	0,0195

Lampiran 17. Nilai *X-scores* di Stasiun Ngurah Rai

n	t₁	t₂	t₃	t₄	t₅	t₆
1.	0,0878	-0,1109	-0,1130	-0,0848	-0,0040	-0,0308
2.	0,0768	-0,0818	-0,1226	-0,0891	-0,0064	-0,0592
3.	0,0734	0,0286	-0,1574	-0,0748	-0,0404	-0,0777
4.	0,0489	0,0035	-0,1553	-0,0225	-0,0622	-0,0888
5.	0,0548	0,0079	-0,1584	-0,0374	-0,0903	-0,1131
6.	0,0481	0,0021	-0,1686	-0,0220	-0,0654	-0,1289
7.	0,0691	-0,0430	-0,1381	-0,0474	0,0224	-0,0955
8.	0,0999	-0,0015	-0,1161	-0,1240	-0,0292	-0,1071
9.	0,0576	0,0086	-0,1403	-0,0318	-0,1153	-0,1163
10.	0,0348	-0,0031	-0,0880	0,0519	-0,0853	-0,0642
11.	0,0375	0,0094	-0,0656	0,0455	-0,0977	-0,0402
12.	0,0352	-0,0090	0,0063	0,0473	-0,0833	0,0681
13.	0,0428	-0,0593	0,0409	0,0016	-0,0760	0,0492
14.	0,0071	-0,0436	-0,0503	0,0379	0,0108	0,0309
15.	0,0083	-0,0018	-0,0288	0,0855	-0,0689	0,0309
⋮	⋮	⋮	⋮	⋮	⋮	⋮
338.	0,0372	0,0494	-0,0127	-0,0059	0,0354	0,0503
339.	0,0182	0,0427	-0,0488	-0,0106	0,0089	0,0110
340.	0,0141	0,0073	-0,0513	0,0395	0,0446	0,0778
341.	0,0278	0,0388	-0,0339	0,0134	-0,0151	0,0397
342.	0,0725	0,0787	-0,0200	-0,0829	-0,0045	0,0739
343.	0,0038	0,0351	-0,0228	0,0247	0,0385	-0,0001
344.	0,0058	0,0475	-0,0614	0,0097	-0,0141	-0,0034
345.	0,0469	-0,0263	-0,0151	-0,0258	0,0326	0,0594

Lampiran 18. Matriks Faktor *Loadings* untuk X di Stasiun
Soekarno Hatta

No.	Variabel	p ₁	p ₂	p ₃	p ₄
1.	IC.dew	46,3331	15,4434	15,8515	-14,5283
2.	IC.hicloud	24,2949	-15,8302	-21,2957	-1,2497
3.	IC1.totrain	30,8804	-14,2463	-13,7212	-4,5214
4.	IC2.totrain	-0,4779	1,7256	-1,6648	-2,0131
5.	IC.lowcloud	13,1464	-2,6275	-24,4347	-3,1173
6.	IC.midcloud	1,9333	-5,7762	3,2052	3,2332
7.	IC.mslp	32,8837	-15,7347	-26,5614	-5,0713
8.	IC1.rhum	31,1322	30,0916	-10,2131	29,4496
9.	IC2.rhum	45,6061	-3,3550	15,7567	-6,9457
10.	IC.shum	2,9719	4,1508	-1,5721	7,0824
11.	IC.surpres	46,5782	15,7145	15,4760	-13,7299
12.	IC1.survis	-34,0172	-28,8794	11,0207	-27,1745
13.	IC2.survis	-16,8163	7,9325	27,5878	7,8170
14.	IC3.survis	0,4592	2,4868	-2,4761	-2,4186
15.	IC1.temp	21,9435	8,4276	-4,4790	4,7540
16.	IC2.temp	-2,8384	19,9527	-5,8173	-14,0014
17.	IC.totcloud	34,4619	-18,2753	-30,7507	-4,1783
18.	IC.uwind	31,8096	-21,5448	6,6270	15,1980
19.	IC.vwind	-9,7269	19,6760	-24,7299	1,1756
20.	IC.windgust	-0,9875	-9,3713	-2,0518	-8,3514

Lampiran 19. Matriks Faktor *Loadings* untuk X di Stasiun
Ngurah Rai

No.	Variabel	p ₁	p ₂	...	p ₅	p ₆
1.	IC.dew	-42,8841	-25,6139	...	-7.6777	3.7025
2.	IC.hicloud	-18,6939	33,4796	...	-22.0854	-11.5336
3.	IC1.totrain	-21,4832	34,0790	...	2.8847	-1.6881
4.	IC1.lowcloud	14,7033	3,5373	...	-22.4874	-7.9577
5.	IC2.lowcloud	0,5813	0,3227	...	1.8625	0.4305
6.	IC.midcloud	22,0663	-40,6069	...	8.4540	-7.9808
7.	IC.mslp	42,1397	-13,2172	...	-15.5355	11.8688
8.	IC1.rhum	13,2515	-16,6062	...	3.9204	0.3265
9.	IC2.rhum	11,2115	-3,4871	...	-4.4431	3.5088
10.	IC.shum	-43,5066	-25,0340	...	-7.1925	3.0277
11.	IC.surpres	-41,8938	16,0182	...	16.7088	-13.7384
12.	IC1.survis	1,4500	-14,9806	...	7.2437	-12.1780
13.	IC2.survis	2,8567	-2,7965	...	1.2521	0.8859
14.	IC1.temp	-41,5454	-4,5303	...	-11.2423	1.7091
15.	IC2.temp	-0,6119	13,3213	...	4.6979	2.8970
16.	IC.totcloud	-20,3813	41,6560	...	-21.8963	-4.9475
17.	IC.uwind	-31,4182	23,9625	...	4.9543	19.7633
18.	IC.vwind	35,3788	-13,3202	...	-7.3132	-12.8842
19.	IC.windgust	27,1319	-1,2780	...	-0.9461	10.0918

Lampiran 20. Matriks Faktor *Loadings* untuk Y di Stasiun
Soekarno Hatta

No.	Variabel	q ₁	q ₂	q ₃	q ₄
1.	T _{max}	6,5313	-6,9068	3,3551	4,0447
2.	T _{min}	-5,4652	-7,0916	-1,6523	2,9766
3.	RH	-12,5257	2,0385	-4,3081	0,1591

Lampiran 21. Matriks Faktor *Loadings* untuk Y di Stasiun
Ngurah Rai

No.	Variabel	q ₁	q ₂	...	q ₂	q ₃
1.	T _{max}	11,4180	6,1271	...	2,9990	2,2440
2.	T _{min}	8,8767	4,1455	...	1,1903	-0,3493
3.	RH	5,6316	-1,5986	...	-2,3987	2,3014

Lampiran 22. Koefisien Regresi SIMPLS di Stasiun Soekarno
Hatta

No.	Variabel	T_{max}	T_{min}	RH
1.	IC.dew	-0,0226	-0,0755	-0,0522
2.	IC.hicloud	0,0148	0,0172	-0,0070
3.	IC1.totrain	0,0184	0,0073	-0,0212
4.	IC2.totrain	-0,0224	-0,0157	0,0049
5.	IC.lowcloud	0,0012	0,0106	0,0084
6.	IC.midcloud	0,0064	0,0063	-0,0030
7.	IC.mslp	-0,0016	0,0021	-0,0087
8.	IC1.rhum	0,0031	-0,0192	-0,0042
9.	IC2.rhum	0,0455	-0,0203	-0,0691
10.	IC.shum	0,0197	0,0126	-0,0029
11.	IC.surpres	-0,0209	-0,0738	-0,0518
12.	IC1.survis	-0,0023	0,0200	0,0055
13.	IC2.survis	0,0231	0,0003	-0,0154
14.	IC3.survis	-0,0120	-0,0116	0,0007
15.	IC1.temp	0,0255	0,0017	-0,0183
16.	IC2.temp	-0,0950	-0,0615	0,0351
17.	IC.totcloud	0,0074	0,0122	-0,0078
18.	IC.uwind	0,1178	0,0554	-0,0677
19.	IC.vwind	-0,0893	-0,0376	0,0564
20.	IC.windgust	-0,0200	-0,0173	-0,0036

Lampiran 23. Koefisien Regresi SIMPLS Stasiun Ngurah Rai

No.	Variabel	T_{max}	T_{min}	RH
1.	IC.dew	-0,0671	-0,0755	-0,0113
2.	IC.hicloud	-0,0305	-0,0014	-0,0155
3.	IC.totrain	0,0173	0,0103	-0,0802
4.	IC1.lowcloud	-0,0020	-0,0040	0,0515
5.	IC2.lowcloud	0,0208	0,0023	0,0052
6.	IC.midcloud	-0,0295	-0,0021	0,0125
7.	IC.mslp	-0,0040	0,0188	0,0109
8.	IC1.rhum	0,0327	-0,0189	-0,0761
9.	IC2.rhum	-0,0301	0,0045	0,0226
10.	IC.shum	-0,0686	-0,0758	-0,0103
11.	IC.surpres	-0,0004	-0,0151	-0,0388
12.	IC1.survis	-0,0343	0,0102	-0,0306
13.	IC2.survis	-0,0105	-0,0002	-0,0089
14.	IC1.temp	-0,0809	-0,0383	0,0409
15.	IC2.temp	0,0862	0,0135	0,0411
16.	IC.totcloud	-0,0065	-0,0006	-0,0084
17.	IC.uwind	0,0416	-0,0012	0,0438
18.	IC.vwind	0,0237	0,0027	0,0325
19.	IC.windgust	0,1175	-0,0121	0,0801

Lampiran 24. Model Prediksi di Stasiun Juanda

$$\hat{y}_{T_{max}} = -0,0496 (\sum_{i=1}^9 e_{i1} \text{dew}_i) + 0,0042 (\sum_{i=1}^9 e_{i2} \text{hicloud}_i) + 0,0134$$

$$(\sum_{i=1}^9 e_{i3} \text{totrain}_i) - 0,0154 (\sum_{i=1}^9 e_{i4} \text{totrain}_i) + 0,0692$$

$$(\sum_{i=1}^9 e_{i5} \text{lowcloud}_i) - 0,0253 (\sum_{i=1}^9 e_{i6} \text{lowcloud}_i) - 0,0196$$

$$(\sum_{i=1}^9 e_{i7} \text{midcloud}_i) + 0,0437 (\sum_{i=1}^9 e_{i8} \text{mslp}_i) + 0,0519$$

$$(\sum_{i=1}^9 e_{i9} \text{rhumi}_i) - 0,0837 (\sum_{i=1}^9 e_{i10} \text{shumi}_i) - 0,1052$$

$$(\sum_{i=1}^9 e_{i11} \text{surpres}_i) + 0,1296 (\sum_{i=1}^9 e_{i12} \text{survis}_i) - 0,0532$$

$$(\sum_{i=1}^9 e_{i13} \text{survis}_i) - 0,2149 (\sum_{i=1}^9 e_{i14} \text{temp}_i) - 0,1089$$

$$(\sum_{i=1}^9 e_{i15} \text{temp}_i) + 0,0207 (\sum_{i=1}^9 e_{i16} \text{totcloud}_i) - 0,2071$$

$$(\sum_{i=1}^9 e_{i17} \text{uwind}_i) - 0,0974 (\sum_{i=1}^9 e_{i18} \text{vwind}_i) - 0,1286$$

$$(\sum_{i=1}^9 e_{i19} \text{vwind}_i) - 0,0029 (\sum_{i=1}^9 e_{i20} \text{IC.windgust}_i)$$

$$\hat{y}_{T_{min}} = -0,1639 (\sum_{i=1}^9 e_{i1} \text{dew}_i) - 0,0089 (\sum_{i=1}^9 e_{i2} \text{hicloud}_i) + 0,1493$$

$$(\sum_{i=1}^9 e_{i3} \text{totrain}_i) - 0,1400 (\sum_{i=1}^9 e_{i4} \text{totrain}_i) + 0,0213$$

$$(\sum_{i=1}^9 e_{i5} \text{lowcloud}_i) - 0,0149 (\sum_{i=1}^9 e_{i6} \text{lowcloud}_i) - 0,0056$$

$$(\sum_{i=1}^9 e_{i7} \text{midcloud}_i) + 0,0569 (\sum_{i=1}^9 e_{i8} \text{mslp}_i) + 0,0418$$

$$(\sum_{i=1}^9 e_{i9} \text{rhumi}_i) - 0,1478 (\sum_{i=1}^9 e_{i10} \text{shumi}_i) - 0,0708$$

$$(\sum_{i=1}^9 e_{i11} \text{surpres}_i) + 0,1014 (\sum_{i=1}^9 e_{i12} \text{survis}_i) - 0,0770$$

$$(\sum_{i=1}^9 e_{i13} \text{survis}_i) - 0,0769 (\sum_{i=1}^9 e_{i14} \text{temp}_i) - 0,0850$$

$$(\sum_{i=1}^9 e_{i15} \text{temp}_i) - 0,0011 (\sum_{i=1}^9 e_{i16} \text{totcloud}_i) + 0,0618$$

$$(\sum_{i=1}^9 e_{i17} \text{uwind}_i) + 0,0356 (\sum_{i=1}^9 e_{i18} \text{vwind}_i) + 0,0330$$

$$(\sum_{i=1}^9 e_{i19} \text{vwind}_i) - 0,0839 (\sum_{i=1}^9 e_{i20} \text{IC.windgust}_i)$$

$$\hat{y}_{RH} = -0,0536 (\sum_{i=1}^9 e_{i1} \text{dew}_i) + 0,0330 (\sum_{i=1}^9 e_{i2} \text{hicloud}_i) - 0,1068$$

$$(\sum_{i=1}^9 e_{i3} \text{totrain}_i) - 0,0296 (\sum_{i=1}^9 e_{i4} \text{totrain}_i) - 0,0161$$

$$(\sum_{i=1}^9 e_{i5} \text{lowcloud}_i) + 0,0209 (\sum_{i=1}^9 e_{i6} \text{lowcloud}_i) - 0,0746$$

$$(\sum_{i=1}^9 e_{i7} \text{midcloud}_i) - 0,0023 (\sum_{i=1}^9 e_{i8} \text{mslp}_i) + 0,0111$$

$$(\sum_{i=1}^9 e_{i9} \text{rhumi}_i) - 0,0198 (\sum_{i=1}^9 e_{i10} \text{shumi}_i) + 0,0660$$

$$(\sum_{i=1}^9 e_{i11} \text{surpres}_i) - 0,1055 (\sum_{i=1}^9 e_{i12} \text{survis}_i) + 0,0018$$

$$(\sum_{i=1}^9 e_{i13} \text{survis}_i) + 0,0889 (\sum_{i=1}^9 e_{i14} \text{temp}_i) - 0,0328$$

$$(\sum_{i=1}^9 e_{i15} \text{temp}_i) - 0,0365 (\sum_{i=1}^9 e_{i16} \text{totcloud}_i) + 0,1279$$

$$(\sum_{i=1}^9 e_{i17} \text{uwind}_i) + 0,1640 (\sum_{i=1}^9 e_{i18} \text{vwind}_i) + 0,2325$$

$$(\sum_{i=1}^9 e_{i19} \text{vwind}_i) + 0,0552 (\sum_{i=1}^9 e_{i20} \text{IC.windgust}_i)$$

Lampiran 25. Model Prediksi di Stasiun Soekarno Hatta

$$\begin{aligned}
 \hat{y}_{T_{max}} &= -0,0226 (\sum_{i=1}^9 e_{i1} \text{dewi}) + 0,0148 (\sum_{i=1}^9 e_{i2} \text{hicloud}_i) + 0,0184 \\
 &\quad (\sum_{i=1}^9 e_{i3} \text{totrain}_i) - 0,0224 (\sum_{i=1}^9 e_{i4} \text{totrain}_i) + 0,0012 \\
 &\quad (\sum_{i=1}^9 e_{i5} \text{lowcloud}_i) + 0,0064 (\sum_{i=1}^9 e_{i6} \text{lowcloud}_i) - 0,0016 \\
 &\quad (\sum_{i=1}^9 e_{i7} \text{midcloud}_i) + 0,0031 (\sum_{i=1}^9 e_{i8} \text{mslp}_i) + 0,0455 \\
 &\quad (\sum_{i=1}^9 e_{i9} \text{rhum}_i) + 0,0197 (\sum_{i=1}^9 e_{i10} \text{rhum}_i) - 0,0209 \\
 &\quad (\sum_{i=1}^9 e_{i11} \text{shum}_i) - 0,0023 (\sum_{i=1}^9 e_{i12} \text{surpres}_i) + 0,0231 \\
 &\quad (\sum_{i=1}^9 e_{i13} \text{survis}_i) - 0,0120 (\sum_{i=1}^9 e_{i14} \text{survis}_i) + 0,0255 \\
 &\quad (\sum_{i=1}^9 e_{i15} \text{temp}_i) - 0,0950 (\sum_{i=1}^9 e_{i16} \text{temp}_i) + 0,0074 \\
 &\quad (\sum_{i=1}^9 e_{i17} \text{totcloud}_i) + 0,1178 (\sum_{i=1}^9 e_{i18} \text{uwind}_i) - 0,0893 \\
 &\quad (\sum_{i=1}^9 e_{i19} \text{vwind}_i) - 0,0200 (\sum_{i=1}^9 e_{i20} \text{IC.windgust}_i) \\
 \hline
 \hat{y}_{T_{min}} &= -0,0755 (\sum_{i=1}^9 e_{i1} \text{dewi}) + 0,0172 (\sum_{i=1}^9 e_{i2} \text{hicloud}_i) + 0,0073 \\
 &\quad (\sum_{i=1}^9 e_{i3} \text{totrain}_i) - 0,0157 (\sum_{i=1}^9 e_{i4} \text{totrain}_i) + 0,0106 \\
 &\quad (\sum_{i=1}^9 e_{i5} \text{lowcloud}_i) + 0,0063 (\sum_{i=1}^9 e_{i6} \text{lowcloud}_i) + 0,0021 \\
 &\quad (\sum_{i=1}^9 e_{i7} \text{midcloud}_i) - 0,0192 (\sum_{i=1}^9 e_{i8} \text{mslp}_i) - 0,0203 \\
 &\quad (\sum_{i=1}^9 e_{i9} \text{rhum}_i) + 0,0126 (\sum_{i=1}^9 e_{i10} \text{rhum}_i) - 0,0738 \\
 &\quad (\sum_{i=1}^9 e_{i11} \text{shum}_i) + 0,0200 (\sum_{i=1}^9 e_{i12} \text{surpres}_i) + 0,0003 \\
 &\quad (\sum_{i=1}^9 e_{i13} \text{survis}_i) - 0,0116 (\sum_{i=1}^9 e_{i14} \text{survis}_i) + 0,0017 \\
 &\quad (\sum_{i=1}^9 e_{i15} \text{temp}_i) - 0,0615 (\sum_{i=1}^9 e_{i16} \text{temp}_i) + 0,0122 \\
 &\quad (\sum_{i=1}^9 e_{i17} \text{totcloud}_i) + 0,0554 (\sum_{i=1}^9 e_{i18} \text{uwind}_i) - 0,0376 \\
 &\quad (\sum_{i=1}^9 e_{i19} \text{vwind}_i) - 0,0173 (\sum_{i=1}^9 e_{i20} \text{IC.windgust}_i) \\
 \hline
 \hat{y}_{RH} &= -0,0522 (\sum_{i=1}^9 e_{i1} \text{dewi}) - 0,0070 (\sum_{i=1}^9 e_{i2} \text{hicloud}_i) - 0,0212 \\
 &\quad (\sum_{i=1}^9 e_{i3} \text{totrain}_i) + 0,0049 (\sum_{i=1}^9 e_{i4} \text{totrain}_i) + 0,0084 \\
 &\quad (\sum_{i=1}^9 e_{i5} \text{lowcloud}_i) - 0,0030 (\sum_{i=1}^9 e_{i6} \text{lowcloud}_i) - 0,0087 \\
 &\quad (\sum_{i=1}^9 e_{i7} \text{midcloud}_i) - 0,0042 (\sum_{i=1}^9 e_{i8} \text{mslp}_i) - 0,0691 \\
 &\quad (\sum_{i=1}^9 e_{i9} \text{rhum}_i) - 0,0029 (\sum_{i=1}^9 e_{i10} \text{rhum}_i) - 0,0518 \\
 &\quad (\sum_{i=1}^9 e_{i11} \text{shum}_i) + 0,0055 (\sum_{i=1}^9 e_{i12} \text{surpres}_i) - 0,0154 \\
 &\quad (\sum_{i=1}^9 e_{i13} \text{survis}_i) + 0,0007 (\sum_{i=1}^9 e_{i14} \text{survis}_i) - 0,0183 \\
 &\quad (\sum_{i=1}^9 e_{i15} \text{temp}_i) + 0,0351 (\sum_{i=1}^9 e_{i16} \text{temp}_i) - 0,0078 \\
 &\quad (\sum_{i=1}^9 e_{i17} \text{totcloud}_i) - 0,0677 (\sum_{i=1}^9 e_{i18} \text{uwind}_i) + 0,0564 \\
 &\quad (\sum_{i=1}^9 e_{i19} \text{vwind}_i) - 0,0036 (\sum_{i=1}^9 e_{i20} \text{IC.windgust}_i) \\
 \hline
 \end{aligned}$$

Lampiran 26. Model Prediksi di Stasiun Ngurah Rai

$$\hat{y}_{T_{max}} = -0,0671 (\sum_{i=1}^9 e_{i1} \text{dew}_i) - 0,0305 (\sum_{i=1}^9 e_{i2} \text{hicloud}_i) + 0,0173$$

$$(\sum_{i=1}^9 e_{i3} \text{totrain}_i) - 0,0020 (\sum_{i=1}^9 e_{i4} \text{lowcloud}_i) + 0,0208$$

$$(\sum_{i=1}^9 e_{i5} \text{lowcloud}_i) - 0,0295 (\sum_{i=1}^9 e_{i6} \text{midcloud}_i) - 0,0040$$

$$(\sum_{i=1}^9 e_{i7} \text{mslp}_i) + 0,0327 (\sum_{i=1}^9 e_{i8} \text{rhum}_i) - 0,0301$$

$$(\sum_{i=1}^9 e_{i9} \text{rhum}_i) - 0,0686 (\sum_{i=1}^9 e_{i10} \text{shum}_i) - 0,0004$$

$$(\sum_{i=1}^9 e_{i11} \text{surpres}_i) - 0,0343 (\sum_{i=1}^9 e_{i12} \text{survis}_i) - 0,0105$$

$$(\sum_{i=1}^9 e_{i13} \text{survis}_i) - 0,0809 (\sum_{i=1}^9 e_{i14} \text{temp}_i) + 0,0862$$

$$(\sum_{i=1}^9 e_{i15} \text{temp}_i) - 0,0065 (\sum_{i=1}^9 e_{i16} \text{totcloud}_i) + 0,0416$$

$$(\sum_{i=1}^9 e_{i17} \text{uwind}_i) + 0,0237 (\sum_{i=1}^9 e_{i18} \text{vwind}_i) + 0,1175$$

$$(\sum_{i=1}^9 e_{i19} \text{IC.windgust}_i)$$

$$\hat{y}_{T_{min}} = -0,0755 (\sum_{i=1}^9 e_{i1} \text{dew}_i) - 0,0014 (\sum_{i=1}^9 e_{i2} \text{hicloud}_i) + 0,0103$$

$$(\sum_{i=1}^9 e_{i3} \text{totrain}_i) - 0,0040 (\sum_{i=1}^9 e_{i4} \text{lowcloud}_i) + 0,0023$$

$$(\sum_{i=1}^9 e_{i5} \text{lowcloud}_i) - 0,0021 (\sum_{i=1}^9 e_{i6} \text{midcloud}_i) + 0,0188$$

$$(\sum_{i=1}^9 e_{i7} \text{mslp}_i) - 0,0189 (\sum_{i=1}^9 e_{i8} \text{rhum}_i) + 0,0045$$

$$(\sum_{i=1}^9 e_{i9} \text{rhum}_i) - 0,0758 (\sum_{i=1}^9 e_{i10} \text{shum}_i) - 0,0151$$

$$(\sum_{i=1}^9 e_{i11} \text{surpres}_i) + 0,0102 (\sum_{i=1}^9 e_{i12} \text{survis}_i) - 0,0002$$

$$(\sum_{i=1}^9 e_{i13} \text{survis}_i) - 0,0383 (\sum_{i=1}^9 e_{i14} \text{temp}_i) + 0,0135$$

$$(\sum_{i=1}^9 e_{i15} \text{temp}_i) - 0,0006 (\sum_{i=1}^9 e_{i16} \text{totcloud}_i) - 0,0012$$

$$(\sum_{i=1}^9 e_{i17} \text{uwind}_i) + 0,0027 (\sum_{i=1}^9 e_{i18} \text{vwind}_i) - 0,0121$$

$$(\sum_{i=1}^9 e_{i19} \text{IC.windgust}_i)$$

$$\hat{y}_{RH} = -0,0113 (\sum_{i=1}^9 e_{i1} \text{dew}_i) - 0,0155 (\sum_{i=1}^9 e_{i2} \text{hicloud}_i) - 0,0802$$

$$(\sum_{i=1}^9 e_{i3} \text{totrain}_i) + 0,0515 (\sum_{i=1}^9 e_{i4} \text{lowcloud}_i) + 0,0052$$

$$(\sum_{i=1}^9 e_{i5} \text{lowcloud}_i) + 0,0125 (\sum_{i=1}^9 e_{i6} \text{midcloud}_i) + 0,0109$$

$$(\sum_{i=1}^9 e_{i7} \text{mslp}_i) - 0,0761 (\sum_{i=1}^9 e_{i8} \text{rhum}_i) + 0,0226$$

$$(\sum_{i=1}^9 e_{i9} \text{rhum}_i) - 0,0103 (\sum_{i=1}^9 e_{i10} \text{shum}_i) - 0,0388$$

$$(\sum_{i=1}^9 e_{i11} \text{surpres}_i) - 0,0306 (\sum_{i=1}^9 e_{i12} \text{survis}_i) - 0,0089$$

$$(\sum_{i=1}^9 e_{i13} \text{survis}_i) + 0,0409 (\sum_{i=1}^9 e_{i14} \text{temp}_i) + 0,0411$$

$$(\sum_{i=1}^9 e_{i15} \text{temp}_i) - 0,0084 (\sum_{i=1}^9 e_{i16} \text{totcloud}_i) + 0,438$$

$$(\sum_{i=1}^9 e_{i17} \text{uwind}_i) + 0,0325 (\sum_{i=1}^9 e_{i18} \text{vwind}_i) + 0,0801$$

$$(\sum_{i=1}^9 e_{i19} \text{IC.windgust}_i)$$



Lampiran 27. Nilai Prediksi di Stasiun Soekarno Hatta


n	T _{max}			T _{min}			RH		
	y	\hat{y}_{SIMPLS}	\hat{y}_{NWP}	y	\hat{y}_{SIMPLS}	\hat{y}_{NWP}	y	\hat{y}_{SIMPLS}	\hat{y}_{NWP}
346.	31,80	31,70	40,51	23,70	24,43	24,84	81,48	81,20	77,32
347.	32,90	31,85	42,96	24,10	24,58	25,48	76,92	81,56	72,89
348.	33,00	32,10	41,53	24,70	24,54	25,44	79,96	80,26	74,26
349.	31,00	32,01	42,50	24,80	24,64	24,71	82,61	80,98	72,18
350.	32,80	33,02	46,30	23,40	24,71	24,49	80,57	77,15	70,11
351.	33,20	32,98	43,69	24,50	24,70	25,49	78,24	77,79	70,38
352.	34,60	32,43	41,89	26,20	24,58	24,31	72,71	79,46	68,26

Lampiran 28. Nilai Prediksi di Stasiun Ngurah Rai


N	T _{max}			T _{min}			RH		
	y	\hat{y}_{SIMPLS}	\hat{y}_{NWP}	y	\hat{y}_{SIMPLS}	\hat{y}_{NWP}	y	\hat{y}_{SIMPLS}	\hat{y}_{NWP}
346.	31,70	31,47	30,41	24,00	25,39	30,41	80,42	80,09	77,27
347.	31,90	31,64	30,14	25,20	25,49	30,14	80,72	80,69	82,10
348.	32,20	31,94	29,61	25,90	26,23	29,61	79,73	81,40	80,16
349.	32,40	31,52	29,67	26,10	25,34	29,67	81,18	80,95	82,29
350.	30,50	31,97	29,87	23,40	25,84	29,87	83,43	82,27	79,93
351.	30,40	31,71	30,37	24,20	25,44	30,37	90,17	81,77	73,68
352.	29,40	31,36	29,51	27,00	24,75	29,51	87,59	80,37	79,38



Lampiran 29. Perbandingan Dugaan Data Observasi, SIMPLS, dan NWP di Stasiun Soekarno Hatta





Lampiran 30. Perbandingan Dugaan Data Observasi, SIMPLS, dan NWP di Stasiun Ngurah Rai





Lampiran 31. Syntax Program R

a. Syntax Reduksi dengan ICA

```
library(fastICA)
file=read.csv("e:/20150101_Juanda_dew2m.csv")
data=scale(as.matrix(file[1:345,4:12]))
x=9
m=9

a=fastICA(data,m,alg.typ="deflation",fun="exp", alpha=1,
  method="R", row.norm=FALSE, maxit=200, tol=0.0001,
  verbose=TRUE)

png('e:/plot.png')
par(mfrow=c(1,3))
plot(a$X, main="Pre-processed data")
plot(a$X%%a$K, main="PCA components")
plot(a$S, main="ICA components")
dev.off()
cor_ica=cor(a$A)
eig_ica=eigen(cor_ica)
fit_ica<-princomp(a$X,cor=TRUE)
sdev<-fit_ica$sdev
sumvar<-sum(eig_ica$value)
p<-ncol(a$S)
var <- matrix(c(0),p,1)
cumvar <- matrix(c(0),p,1)
for(i in 1:p){
  var[i] <- eig_ica$value[i]/sumvar
  if (i == 1) {cumvar[i] <- var[i]}
  else
    cumvar[i] <- var[i] + cumvar[i-1]
}

write.csv(cbind(sdev,var,cumvar),"e:/sdev_var_cumvar.csv")
ic=as.matrix(data)%%eig_ica$vectors[1:9,1:x]
write.csv (eig_ica, file="e:/eigen_ica.csv")
write.csv (ic, file="e:/comp_ica.csv")
```

b. Syntax SIMPLS

```

library(pls)
library(plsdepot)
ica<-read.csv("E:/ica_juanda.csv",header=T)
tr<-ica[1:352,1:23]
Ytr<-as.matrix(ica[1:345,21:23])
Xtr<-as.matrix(ica[1:345,1:20])
Yts<-as.matrix(ica[346:352,21:23])
Xts<-as.matrix(ica[346:352,1:20])
lm<-mvr
(Tmax+Tmin+RH~IC.dew2m+IC.hicloud+IC1.totrain+IC2.totrain+
IC1.lowcloud+IC2.lowcloud+IC.midcloud+IC.mslp+IC.rhum+
IC.shum+IC.surpres+IC1.survis+IC2.survis+IC1.temp+IC2.temp
+IC.totcloud+IC.uwind+IC1.vwind+IC2.vwind+IC.windgust,data
=as.data.frame(scale(tr)),ncomp=20,method="kernelpls")
summary(crossval(lm,segments=20))
trsimpls<-simpls.fit(Xtr,Ytr,14)
write.csv(cbind(trsimpls$scores),"x_scores.csv")
write.csv(cbind(trsimpls$loadings),"x_loadings.csv")
write.csv(cbind(trsimpls$Yscores),"y_scores.csv")
write.csv(cbind(trsimpls$Yloadings),"y_loadings.csv")
write.csv(cbind(trsimpls$projection),"old_weight.csv")
write.csv(cbind(trsimpls$Xmeans),"x_means.csv")
write.csv(cbind(trsimpls$Ymeans),"y_means.csv")
write.csv(cbind(trsimpls$Xvar),"x_var.csv")
trsimpls.B<-
trsimpls$projection%*%solve(t(trsimpls$scores)%*%trsimpls
$scores)%*%t(trsimpls$scores)%*%as.matrix(Ytr)
write.csv(cbind(trsimpls.B),"koefisien.csv")
Ytr.hat<-as.matrix(Xtr)%*%trsimpls.B
restr<-abs(Ytr.hat-Ytr)

```

```

write.csv(cbind(Ytr,Ytr.hat,restr),"E:/SIMPLS_JUANDA/evaltr-
simpls.csv")
Yts.hat<-as.matrix(Xts)%*%trsimpls.B
rests<-abs(Yts.hat-Yts)
write.csv(cbind(Yts,Yts.hat,rests),"E:/SIMPLS_JUANDA/evalts-
simpls.csv")
R2tr.Tmaks<-1-(sum((Ytr[,1]-Ytr.hat[,1])^2)/sum((Ytr[,1]-
mean(Ytr[,1]))^2))
R2tr.Tmin<-1-(sum((Ytr[,2]-Ytr.hat[,2])^2)/sum((Ytr[,2]-
mean(Ytr[,2]))^2))
R2tr.RH<-1-(sum((Ytr[,3]-Ytr.hat[,3])^2)/sum((Ytr[,3]-
mean(Ytr[,3]))^2))
R2tr.Tmaks
R2tr.Tmin
R2tr.RH

```

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa
Departemen Statistika FMIPA ITS

Nama : Vira Oktavia Kurniasari

NRP : 1313 100 007

menyatakan bahwa data yang digunakan dalam Tugas Akhir/Thesis ini merupakan data sekunder yang diambil dari penelitian/buku/Tugas Akhir/Thesis/publikasi lainnya yaitu:

Sumber : Data Penelitian Sutikno dengan Judul
"Pengembangan Model Prakiraan Cuaca Melalui Model Output Statistik Dengan Pendekatan Linear dan Non-Linear Dalam Antisipasi Bencana Hidrometeorologi"

- Keterangan : 1. Data suhu maksimum, minimum, dan kelembapan pada Stasiun Meteorologi Juanda, Sockarno Hatta, dan Ngurah Rai periode 2 Januari 2015 - 10 Desember 2016
2. *Output* data NWP WRF-EMS periode 2 Januari 2015 - 10 Desember 2016

Surat pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

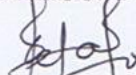
Mengetahui,
Pembimbing Tugas Akhir



Dr. Sutikno, S.Si, M. Si
NIP. 19710313 199702 1 001

Surabaya,

Mahasiswa



Vira Oktavia K
NRP 1313 100 007

BIODATA PENULIS



Vira Oktavia Kurniasari

Lahir di Lumajang pada tanggal 6 Oktober 1994. Perempuan yang akrab disapa Vira ini merupakan anak bungsu dari tiga bersaudara dari pasangan Bapak Agus Rubiawan dan Ibu Soegijarti. Berdomisili di Lumajang, Vira menempuh pendidikan formalnya mulai dari SDN Kutorenon 1, SMPN 1 Sukodono, dan SMAN 2 Lumajang, hingga melanjutkan studi sebagai

mahasiswa S1 Statistika di Institut Teknologi Sepuluh Nopember Surabaya melalui jalur SNMPTN pada tahun 2013. Semasa kuliah, Vira aktif di organisasi kemahasiswaan ITS tingkat jurusan yakni HIMASTA-ITS pada periode 2014-2015 sebagai *staff* Departemen Sosial Masyarakat dan menjabat sebagai Sekretaris Departemen Sosial Masyarakat pada periode 2015-2016. Ia juga pernah menjadi asisten dosen mata kuliah Teknik Sampling & Survey dan Pengendalian Kualitas Statistik, serta melaksanakan kerja praktek di Kantor Pusat Badan Meteorologi, Klimatologi, dan Geofisika Jakarta. Pada tahun 2017, Vira berhasil menyelesaikan Tugas Akhir dengan Judul “*Model Output Statistics* untuk Prakiraan Cuaca Jangka Pendek Menggunakan *Statistically Inspired Modification of Partial Least Square*”. Bagi pembaca yang memiliki saran, kritik, atau ingin berdiskusi lebih lanjut dengan penulis, dapat menghubungi melalui *email* : viratavia6@gmail.com.